



**UNIVERSIDADE
FEDERAL
DE PERNAMBUCO**



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Departamento de Eletrônica e Sistemas



Programa de Pós-Graduação em Engenharia Elétrica

Doutorado em Engenharia Elétrica

Gilson José Alves

**SISTEMA PARA AUXÍLIO DIAGNÓSTICO DA
DOENÇA DE ALZHEIMER: UMA
APLICAÇÃO COM REDE NEURAL
ARTIFICIAL ADAPTATIVA**

Recife

2025

Gilson José Alves

**SISTEMA PARA AUXÍLIO DIAGNÓSTICO DA
DOENÇA DE ALZHEIMER: UMA
APLICAÇÃO COM REDE NEURAL
ARTIFICIAL ADAPTATIVA**

Tese de Doutorado apresentada ao Departamento de Eletrônica e Sistemas, como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica. (Dsc.)

Área de concentração: Eletrônica.

Orientador(a): Prof. Marco Aurélio Benedetti Rodrigues, D.Sc.

Coorientador(a): Prof. Renato Evangelista de Araújo, D.Sc.

Coordenador: Prof. Gustavo Medeiros de Souza Azevedo, D.Sc.

Recife
2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Alves, Gilson José.

Sistema para auxílio diagnóstico da doença de Alzheimer: uma aplicação com rede neural artificial adaptativa / Gilson José Alves. - Recife, 2025.

179f.: il.

Tese (Doutorado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Elétrica, 2025.

Orientação: Marco Aurélio Benedetti Rodrigues.

Coorientação: Renato Evangelista de Araújo.

Inclui referências, apêndices e anexos.

1. Rede neural artificial; 2. doença de Alzheimer; 3. reconhecimento de padrões; 4. EEG. I. Rodrigues, Marco Aurélio Benedetti. II. Araújo, Renato Evangelista de. III. Título.

UFPE-Biblioteca Central

Gilson José Alves

**SISTEMA PARA AUXÍLIO DIAGNÓSTICO DA
DOENÇA DE ALZHEIMER: UMA
APLICAÇÃO COM REDE NEURAL
ARTIFICIAL ADAPTATIVA**

Tese de Doutorado apresentada ao Departamento de Eletrônica e Sistemas, como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica. (Dsc.)

Aprovado em: 28/02/2025

Banca Examinadora

Prof. Marco Aurélio Benedetti Rodrigues, D.Sc.
Universidade Federal de Pernambuco

Prof. Miguel Fernando Paiva Velhote, D.Sc.
Universidade do Porto - Portugal

Prof. Fernando Ferreira de Carvalho, D.Sc.
Instituto Federal de Pernambuco

Prof. Gilson Jerônimo da Silva Junior, D.Sc.
Universidade Federal de Pernambuco

Prof. Guilherme Nunes Melo, D.Sc.
Universidade Federal de Pernambuco

Prof. Lauro Rodrigo Gomes da Silva Lourenço Novo, D.Sc.
Universidade Federal de Pernambuco

*Dedico este trabalho aos meus
filhos, João Vitor, Laiz Maria,
Ívina Liz e Bernardo Luiz, à
minha esposa, Lícia Magna, à
minha mãe, Maria de Lourdes, e
ao meu pai, Arlindo Alves (in
memorian). Todos estes que,
pelo simples fato de existirem em
minha vida, tornaram-se minha
fonte de motivação e resiliência.*

Agradecimentos

Primeiramente, agradeço a Deus por todas as bênçãos com as quais me sinto permanentemente agraciado.

Agradeço aos meus queridos pais, o Seu Arlindo (*in memoriam*) e a Dona Lourdes, pelo amor incondicional que sempre me dedicaram, sendo os meus "*fãs números 1 de todas as horas*".

Agradeço a Lícia Magna, minha querida esposa, por sua compreensão, e ao seu pai, o seu Germano (*in memoriam*), por me ter confiado uma pessoa tão especial.

Agradeço aos meus amados filhos, o João Vitor, a Laiz Maria, a Ívina Liz e o Bernardo Luiz, pelo carinho e compreensão às minhas inúmeras ausências, durante o desenvolvimento deste trabalho.

Agradeço aos meus irmãos Alexandre, Rosineide e Isaldo, pela torcida empolgada de sempre. Através deles, estendendo minha gratidão a toda família.

Agradeço, de modo muito singular, aos meus orientadores, os professores Marco Aurélio Benedetti e Renato Evangelista, por sua orientação zelosa e descontraída, disponibilidade permanente para ajudar, pelo uso de palavras amigas, de estímulo, compreensão e apoio, que me foram essenciais e sem as quais este trabalho não seria concluído.

Agradeço ao coordenador do PPGEE, o Prof. Gustavo de Medeiros, por sua pronta assistência, todas as vezes em que precisei.

Agradeço à banca examinadora, composta pelos Professores Miguel Fernando Paiva Velhote, Fernando Ferreira de Carvalho, Gilson Jerônimo da Silva Junior, Guilherme Nunes Melo e Lauro Rodrigo Gomes da Silva Lourenco Novo, por suas valiosas sugestões e atenção dedicadas ao melhoramento deste trabalho.

Agradeço à Andrea Tenório, da secretaria do PPGEE, que ao longo de toda jornada sempre me tratou com grande zelo e atenção – Sua contribuição para a continuidade e conclusão dessa minha etapa acadêmica foi de valor inestimável. A ela, a minha gratidão, que se estende a toda UFPE.

Agradeço aos membros do GPEB - Grupo de Pesquisa em Engenharia Biomédica da UFPE, aqui representado por Érico Cavalcante, Ana Vitória, Breno Bispo, Malki-gedheq Silva, Naelso Cunha, Raquel, Carol e Catarina; e à Prof^a Patrícia Lessa – Todos, que liderados pelo Prof. Marco Aurélio Benedetti, promovem um ambiente de convívio saudável, em todos os aspectos. Ainda na UFPE, agradeço aos colegas contemporâneos de jornada, aqui representados por Fabiano Gabriel, Henrique Müller, Jacinaldo, Leonardo Bruno, Cleber Renan, Wiliam Guterres, Diogo Roberto, Emmanuel, José Mário, José Otávio, Marilu Silva, que com sua amizade tornaram essa fase mais agradável.

Agradeço aos amigos e amigas, aqui representados por Antônio Francisco, Danielle Lanzer, Susi e Raurium Bacalhau, Karla e Jorge Pilar. Alguns, ainda que nem saibam o que eu esteja fazendo, bem sei que sempre torcem por mim.

E finalmente, pelo auxílio e apoio nos momentos oportunos, agradeço ao IFPE, principalmente aos que fazem o DASE - Departamento Acadêmico de Sistemas Eletrônicos – aos colegas professores, colaboradores administrativos e terceirizados, todos aqui representados pelos professores Pedro Paulo Marques, Carlos Sivini, Jorge Santos e Jairson M. B. Santos, que já se encontram no plano espiritual e com os quais tive uma grata experiência de convívio.

Gilson J. Alves.

Resumo da Tese de Doutorado apresentada ao Departamento de Eletrônica e Sistemas, como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica. (Dsc.)

SISTEMA PARA AUXÍLIO DIAGNÓSTICO DA DOENÇA DE ALZHEIMER: UMA APLICAÇÃO COM REDE NEURAL ARTIFICIAL ADAPTATIVA

Gilson José Alves

As doenças neurológicas (DNs) são distúrbios que afetam o Sistema Nervoso Central (SNC), composto pelo encéfalo e pela medula espinhal, responsáveis pelo processamento e transmissão de informações no organismo. Existem mais de 600 tipos de DNs, incluindo tumores cerebrais, epilepsia, doença de Alzheimer (DA) e acidente vascular cerebral (AVC). As causas dessas enfermidades são variadas, considerando a complexidade do SNC, e podem incluir fatores genéticos, estilo de vida, infecções e lesões físicas. Alterações na atividade elétrica cerebral são comuns em muitas DNs e, em alguns casos, podem ser detectadas antes do surgimento de sintomas clínicos evidentes. A DA, em particular, apresenta desafios no diagnóstico precoce, pois seus sinais clínicos geralmente emergem em estágios avançados. Este estudo propõe um sistema de auxílio diagnóstico para a DA, baseado em inteligência artificial, utilizando uma rede neural artificial (RNA) associada ao processamento digital de sinais. O sistema analisa sinais de eletroencefalograma (EEG), extraindo padrões nas bandas de frequência delta δ , teta θ , alfa α e beta β . Esses padrões, obtidos por meio de parâmetros como densidade espectral e coerência, são utilizados como entrada para a RNA, treinada para distinguir indivíduos com e sem DA. Os testes realizados demonstraram a eficácia do sistema na discriminação entre portadores e não portadores da DA, com sensibilidade de 80%, especificidade de 94,59% e acurácia de 94%. Para a distinção entre indivíduos saudáveis e não saudáveis,

os valores obtidos foram: sensibilidade de 80%, especificidade de 96,66% e acurácia de 70%. Esses resultados representam uma contribuição efetiva aos métodos diagnósticos de DNs. As possíveis aplicações desse sistema incluem o suporte às equipes médicas no diagnóstico precoce da DA, possibilitando a adoção de intervenções que possam retardar ou limitar sua progressão. Dessa forma, o estudo contribui para a melhoria da qualidade de vida dos pacientes e de seus familiares, além de aprimorar as abordagens clínicas no manejo da doença.

Palavras-chave: Rede neural artificial, doença de Alzheimer, reconhecimento de padrões, EEG.

Abstract of the Doctoral Thesis presented to the Department of Electronics and Systems, as part of the requirements for obtaining the degree of Doctor in Electrical Engineering. (Dsc.)

**SYSTEM FOR DIAGNOSTIC AID IN ALZHEIMER'S DISEASE: AN
APPLICATION WITH ADAPTIVE ARTIFICIAL NEURAL
NETWORK**

Gilson José Alves

Neurological diseases (NDs) are disorders that affect the Central Nervous System (CNS), which consists of the brain and spinal cord, responsible for processing and transmitting information throughout the body. There are over 600 types of NDs, including brain tumors, epilepsy, Alzheimer's disease (AD), and stroke. The causes of these diseases are diverse, considering the complexity of the CNS, and may include genetic factors, lifestyle, infections, and physical injuries. Changes in brain electrical activity are common in many NDs and, in some cases, can be detected before the emergence of evident clinical symptoms. AD, in particular, poses challenges for early diagnosis, as its clinical signs generally appear in advanced stages. This study proposes a diagnostic support system for AD based on artificial intelligence, utilizing an artificial neural network (ANN) combined with digital signal processing. The system analyzes electroencephalogram (EEG) signals, extracting patterns in delta δ , theta θ , alpha α and beta β frequency bands. These patterns, derived from parameters such as spectral density and coherence, serve as inputs for the ANN, which is trained to distinguish between individuals with and without AD. The tests conducted demonstrated the system's effectiveness in differentiating between AD carriers and non-carriers, achieving a sensitivity of 80%, specificity of 94.59%, and accuracy of 94%. For distinguishing between healthy and non-healthy individuals, the obtained values were: sensitivity of 80%, specificity of 96.66%, and accuracy of

70%. These results represent a significant contribution to diagnostic methods for NDs. The potential applications of this system include assisting medical teams in the early diagnosis of AD, enabling the adoption of interventions that may delay or limit disease progression. Thus, this study contributes to improving the quality of life of patients and their families, as well as enhancing clinical approaches in disease management.

Keywords: Artificial neural network, Alzheimer's disease, pattern recognition, EEG.

Lista de Figuras

3.1	Sistema nervoso central.	37
3.2	Neurônio biológico humano.	38
3.3	Neurônios conectados em rede.	39
3.4	Potencial de ação celular.	39
3.5	Duração do potencial de ação.	40
3.6	Sentido do impulso nervoso.	41
3.7	Sinal EEG e sua densidade espectral de potência.	49
3.8	Regiões do cérebro.	53
3.9	Neurônio artificial.	54
3.10	Semelhança entre os neurônios humano e artificial.	54
3.11	Rede Neural Artificial em blocos.	55
3.12	Rede Neural com 1 camada intermediária.	56
3.13	Rede Neural implementada.	57
3.14	Neurônio artificial sob efeito de uma função de ativação.	69
3.15	Gráficos da função Sigmóide e de sua derivada.	70
3.16	Gráficos da função Tangente hiperbólica e de sua derivada.	71
3.17	Gráficos da função ReLU e de sua derivada.	72
3.18	Gráficos da função Swish e de sua derivada.	74
4.1	Sinais biológicos: a) no coração b) no cérebro c) nos olhos d) nos músculos.	77
4.2	EEG: Interface de eletrodos para método invasivo.	79
4.3	EEG: Interface de eletrodos para método não-invasivo.	80

4.4	EEG: Sistema 10-20 para posicionamento de eletrodos.	81
4.5	EEG: Sistema 10-10 para posicionamento de eletrodos.	82
4.6	EEG: Sistema 10-5 para posicionamento de eletrodos.	82
4.7	Gradiente descendente.	90
4.8	Sinal de EEG e wavelet Daubechies 2.	94
4.9	Decomposição 4-DWT.	95
4.10	Pontos de aquisição versus Atividades relacionadas.	98
5.1	RNA - Entrada do sinal de EEG.	101
5.2	Deslocamento do sinal na camada de entrada da RNA.	102
5.3	RNA com propagação ativada por função sigmoide.	103
5.4	Macro fluxo do Sistema.	105
5.5	Módulos de software do Sistema.	106
5.6	Blocos de pré-processamento e RNAA.	107
5.7	Análise wavelet em sinal EEG com duração de 2s.	108
5.8	Topologia de RNA-1.	109
5.9	Topologia de RNA-2.	110
5.10	RNA-1: Amostragens de treinamento.	114
5.11	RNA-1: Amostragens de validação (1 a 5).	115
5.12	RNA-1: Amostragens de validação (6 a 10).	115
5.13	RNA-1: Amostragens de validação (11 a 15).	116
5.14	RNA-1: Curva de erro no treinamento e validação.	116
5.15	RNA-1: Erro médio em cada neurônio da camada de saída.	117
5.16	RNA-2: Amostragens de validação (1 a 5).	117
5.17	RNA-2: Amostragens de validação (6 a 10).	118
5.18	RNA-2: Curva de erro no treinamento e validação.	119
5.19	RNA-2: Erro médio em cada neurônio da camada de saída.	119

Lista de Tabelas

2.1	IEEE - Pesquisa inicial.	30
2.2	Science Direct - Pesquisa inicial.	31
2.3	Springer - Pesquisa inicial.	31
2.4	Pubmed - Pesquisa inicial.	31
2.5	PMC - Pesquisa inicial.	31
2.6	ACM - Pesquisa inicial.	31
2.7	Grau de relevância dos aspectos avaliados.	33
2.8	Referências selecionadas	35
5.1	RNA-1: Análise da validação.	118
5.2	RNA-2: Análise da validação.	120
5.3	Indivíduos selecionados para teste.	123
5.4	Teste AD <i>versus</i> Não AD.	124
5.5	Teste HE <i>versus</i> Não HE.	125

Lista de Abreviaturas e Siglas

μV	microvolt
ANI	Acoplamento Neuronal Intrínseco
AV	Atrioventricular
BP	Backpropagation
BPTT	Backpropagation through time
CCL	Comprometimento Cognitivo Leve
cohe	Sinal de coerência
conv	Sinal de convolução
DA	Doença de Alzheimer
DN	Doença neurológica
DR	Dados de referência
DR	Dados de referência
dsp	Sinal de densidade de potência
ECG	Eletrocardiograma
EEG	Eletroencefalograma
EOG	Eletrooculograma
fA	Função de ativação
FN	Falsos negativos
FP	Falsos positivos
FTD	Grupo de portadores da doença fronto-temporal	
GFS	Global Field Synchronization
GR	Grau de relevância
HD	Hipótese diagnóstica
HE	Grupo de não-portadores de doença neurológica	
IA	Inteligência artificial
IFPE	Instituto Federal de Pernambuco

JW	Janela wavelet
MEG	Magneto-encefalografia
MLP	Multi Layer Perceptron
ms	milisegundo
mV	milivolt
nm	nanometro
PDS	Processamento digital de sinais
ReLu	Função linear unitária retificada
RNA	Rede neural artificial
RNA-D	Rede neural artificial dinâmica
RSL	Revisão sistemática da literatura
RV-	Razão de verossimilhança negativo
RV+	Razão de verossimilhança positivo
SA	Sinoatrial
SNC	Sistema nervoso central
UFPE	Universidade Federal de Pernambuco
VN	Verdadeiros negativos
VP	Verdadeiros positivos
VPN	Valor preditivo negativo
VPP	Valor preditivo positivo
WT	Wavelet transform

Sumário

1	Introdução	21
1.1	Contextualização	22
1.2	Motivação	24
1.3	Objetivos	25
1.3.1	Objetivos específicos	25
1.4	Organização deste trabalho	26
2	Revisão Sistemática da Literatura	28
2.1	Ferramentas aplicadas nesta RSL	28
2.2	Palavras-chave	29
2.2.1	Escolha das palavras-chave	29
2.3	Seleção de referências	30
2.3.1	Identificação	30
2.3.2	Triagem	32
2.3.3	Elegibilidade	32
2.4	Estado da Arte	33
3	Sistema Nervoso Humano e Rede Neural Artificial	37
3.1	O neurônio biológico humano	38
3.2	O potencial elétrico humano	39
3.3	Doenças neurológicas	41
3.3.1	Aplicação de EEG no diagnóstico e tratamento de doenças neurológicas	42

	18
3.3.2	Métodos aplicados para diagnóstico da doença de Alzheimer 42
3.3.3	O diagnóstico da doença de Alzheimer através de sinais de EEG 43
3.3.4	Avaliação do processo diagnóstico 44
3.3.5	Crítérios para hipótese diagnóstica 46
3.4	Caracterização do sinal de EEG 47
3.4.1	Densidade espectral de potência 47
3.4.2	Coerência 50
3.5	Rede Neural Artificial 53
3.5.1	O neurônio artificial 53
3.5.2	Estrutura de uma RNA 54
3.5.3	RNA estática, dinâmica e adaptativa 58
3.5.4	Crítérios considerados para escolha da RNA 60
3.5.5	Topologias de implementação de RNA 61
4	Aquisição e Processamento de Sinais Bioelétricos 76
4.1	Sinais elétricos do cérebro 77
4.1.1	Morfologia do EEG 78
4.1.2	EEG não-invasivo: Padrões para posicionamento dos eletrodos 80
4.1.3	Interpretação de um sinal de EEG 83
4.2	Técnicas para processamento de sinais bioelétricos 84
4.2.1	Inteligência Artificial aplicada a sinais bioelétricos 85
4.2.2	Inteligência Artificial - Ferramentas auxiliares 86
4.2.3	Transformadas Wavelet 89
4.3	A atividade cerebral 94
4.4	Identificação de doenças neurológicas através de sinais de EEG 96
4.5	Regiões de aquisição dos sinais de EEG 97
5	Rede Neural Artificial Adaptável para Identificação da Doença de
	Alzheimer 100
5.1	Entrada do sinal de EEG na rede 101

5.2	Propagação dos dados através das camadas da RNA	102
5.3	Pré-processamento do sinal de EEG	104
5.3.1	A extração dos padrões de densidade e coerência do sinal EEG	107
5.4	RNA-1 e RNA-2	108
5.4.1	RNA-1: Identificação dos perfis HE, AD e FTD	108
5.4.2	RNA-2: Identificação dos perfis AD1 e AD2-3	109
5.5	Inicialização de RNA-1 e RNA-2	111
5.6	Treinamento e validação de RNA-1 e RNA-2	111
5.6.1	RNA-1 e RNA-2: Execução do treinamento e validação	113
5.7	Testes de RNA-1	120
5.7.1	Seleção dos dados para teste de RNA-1	122
5.7.2	Testes realizados com RNA-1	124
6	Discussão e Conclusões	128
6.1	Discussão	129
6.2	Conclusão	130
6.3	Trabalhos Futuros	132
6.4	Artigos Publicados em Periódicos e Conferências	134
	Referências	135
	Apêndice A Amostragens do Treinamento e Validação	149
	Apêndice B Janelas gráficas do teste	168
	Anexo A Referência da Base de Dados OpenNeuro	175

*”Não há fé inabalável, senão aquela
que pode encarar a razão face à
face, em todas as épocas da
Humanidade.”*

O Evangelho segundo o
Espiritismo.

Capítulo 1

Introdução

Doenças neurológicas (DN), como a doença de Alzheimer (DA), provocam alteração da atividade elétrica cerebral e, por consequência, dos padrões fisiológicos por ela emitidos. O diagnóstico preciso da DA, que segue orientação da Academia Brasileira de Neurologia, é consideravelmente complexo, envolvendo análises com grande número de avaliações neuro-cognitivas e comportamentais, exames neurofisiológicos, laboratoriais, além de eletroencefalograma (EEG) (NITRINI et al.,2005).

Os biomarcadores consistem em sinais biológicos mensuráveis que podem indicar a presença de processo biológico ou patogênico em um organismo, ou ainda a sua resposta a um fármaco (GOMES,2015;NITZSCHE; MORAES; JÚNIOR,2015). Em relação à DA, são muito aplicados em protocolos de pesquisa, mas na rotina médica isso não se repete, o que retarda consideravelmente a conclusão do diagnóstico da doença (SOUZA et al.,2014).

Por outro lado, a análise de sinais de EEG permite quantificar a alteração provocada por doenças neurológicas. Nos sinais de EEG de um indivíduo, são encontrados padrões de ondas, que são diretamente associáveis ao seu nível de atividade cerebral. São as ondas Delta δ , Teta θ , Alfa α e Beta β . Nessa mesma ordem, elas contemplam os níveis de menor aos de maior atividade cerebral. E por caracterizarem essa dinâmica, a identificação de padrões dessas ondas pode ser aplicada para distinguir o estado de atividade em que se encontra um indivíduo. Por exemplo, quando esse indivíduo se encontra em estado de sono profundo ou quando em atividade men-

tal que requer concentração ou descansando após atividade intensa ou em estado de fadiga (SOUZA,2023).

No EEG de portadores de DA, ocorre variação desses padrões associados às ondas cerebrais Delta δ , Teta θ , Alfa α e Beta β (SANDMANN et al.,1996). A identificação dessa variação, seguido do cálculo de sua potência espectral é, então, comparada com dados de referência, que são relativos a EEG de não-portadores de DN. O resultado dessa comparação, quando discrepante, é usada como subsídio para fundamentar hipótese diagnóstica (HD) relativa a tais portadores de DN.

Sendo assim, a adição de recurso computacional para análise de seus resultados se configura numa importante ferramenta para auxílio ao processo diagnóstico de doenças relacionadas ao sistema neurológico, sendo forte aliada do médico assistente, não somente no diagnóstico, mas também para orientar na escolha da terapia mais adequada a cada paciente.

Atualmente, avanços tecnológicos antes inimagináveis fazem parte do nosso dia a dia. Máquinas autônomas já são capazes de tomar decisões com base no aprendizado adquirido por meio da exposição a estímulos externos. Algumas dessas máquinas podem até agir de forma semelhante à cognição humana, respondendo a um conjunto de estímulos e fatores da mesma maneira que uma pessoa o faria. Tudo isso é fruto do aprimoramento de um conjunto de técnicas pertencentes ao campo da Inteligência Artificial (IA), cujos conceitos são apresentados no Capítulo 3. As técnicas de IA se propõem a implementar estruturas que funcionam de forma semelhante ao cérebro humano (RUSSELL; NORVIG,2016).

1.1 Contextualização

Projeções oficiais do crescimento populacional brasileiro apontam um patamar de 233 milhões de habitantes, em 2050. Na mesma direção, também cresce o número de idosos, que neste mesmo ano já representarão aproximadamente 22% de toda população (ESTATÍSTICA,2017). Daí, também decorre que crescerão as demandas por serviços médicos que, por sua vez, refletirão sobre o sistema de saúde, pois é

normalmente nessa faixa etária que surgem os primeiros sinais de doenças decorrentes do envelhecimento do corpo humano. Dentre as muitas doenças que acometem os idosos, encontram-se aquelas que atingem diretamente o Sistema Nervoso Central (SNC), provocando sérios prejuízos à sua integridade física e mental, as doenças neurológicas. A DA é uma dessas doenças, que costuma acometer indivíduos com idade superior a 70 anos (ASSOCIATION,2019). Ela surge quando ocorre mau processamento de proteínas do sistema nervoso central. Caracteriza-se por perda de memória progressiva, acompanhada de disfunção cognitiva, com significativo impacto na qualidade de vida do paciente e, por consequência, também dos seus familiares, amigos e todas as pessoas de seu convívio mais próximo (RODRIGUES et al.,2020;BARROS;CORDEIRO; CARVALHO,2019). É a forma mais comum de demência neurodegenerativa em indivíduos idosos e representa mais de 50% dos casos de demência na população idosa (CALIL et al.,2020).

Se a DA for identificada nos primeiros meses de seu acometimento, quando na maioria das vezes os principais sintomas ainda não se manifestaram de forma perceptível, seu tratamento pode ser antecipado, através de terapia especializada, conduzida por equipe multidisciplinar. Esta atenção antecipada contribui significativamente para retardar a evolução dos sintomas da DA, o que representa uma expectativa de melhor qualidade de vida para o paciente e demais envolvidos (RASMUSSEN; LANGERMAN,2019;EIKELBOOM et al.,2019). Para viabilizar isto, é muito importante que o processo diagnóstico da DA, atualmente realizado através de exames laboratoriais e clínicos, seja melhorado sob alguns aspectos, de modo que seja possível concluí-lo antes que o paciente comece a apresentar os seus sintomas mais típicos.

Sendo assim, com o objetivo de oferecer uma ferramenta computacional capaz de auxiliar no processo diagnóstico de doenças neurológicas, este trabalho apresenta um sistema baseado em redes neurais artificiais, uma técnica de IA, combinada ao processamento digital de sinais de EEG, seguido de estratégia que permita a discriminação de portadores e não-portadores de DNs. Sua principal contribuição é

viabilizar esta identificação também no estágio precoce da DN, o que permite a antecipação de terapias médicas capazes de retardar a sua evolução. Como consequência, promove-se uma melhor qualidade de vida ao seu portador.

1.2 Motivação

A Sincronização de Campo Global, mais conhecida por sua denominação original Global Field Synchronization (GFS) é um teste realizado a partir de um sinal de EEG que estima, de modo diretamente proporcional, a presença de processos funcionais em suas diferentes bandas de frequência, atribuindo um valor de GFS para cada faixa de frequência ((MA et al.,2014). Sabe-se que os portadores de DA apresentam baixo GFS para as faixas associadas aos padrões Alfa α e Beta β , enquanto alto GFS para a faixa Delta δ ((DURONGBHAN et al.,2019). Essa correlação mostra que a percepção de existência da DA pode ser aprimorada pela análise qualitativa do sinal de EEG, especialmente quanto a potência espectral associada a seus padrões de frequência. Por isso, a decisão por implementar uma ferramenta para aprimoramento dessa análise.

As técnicas de IA se mostram eficazes para identificação de padrões. A motivação deste trabalho se expressa pela possibilidade de aplicar tais técnicas na implementação de ferramenta capaz de auxiliar no processo diagnóstico de doenças neurológicas, adicionando a ele maior agilidade. Isto poderá viabilizar a adoção de estratégias terapêuticas mais adequadas a cada caso, que se refletirá numa melhoria da qualidade de vida das pessoas afetadas por tais doenças.

O trabalho aqui apresentado tem como base uma das técnicas de IA, Redes Neurais Artificiais, RNA, sendo a sua finalidade auxiliar no processo diagnóstico de doenças neurológicas.

1.3 Objetivos

Este trabalho tem como objetivo geral propor um sistema para auxílio ao processo diagnóstico da Doença de Alzheimer, usando uma Rede Neural Artificial Dinâmica Adaptativa, RNAA capaz de identificar padrões de ondas cerebrais Delta δ , Teta θ , Alfa α e Beta β a partir de sinais de EEG, previamente processados.

1.3.1 Objetivos específicos

Para alcance do objetivo geral, foram definidas as seguintes ações:

- Aplicar módulo de pré-processamento do sinal de EEG para extração de sinais a serem usados como referência de treinamento de uma RNAA;
- implementar a RNAA capaz de identificar os padrões de EEG nas faixas Delta δ , Teta θ , Alfa α e Beta β ;
- realizar testes com sinais de EEG de portadores e não-portadores da doença de Alzheimer, armazenados em base de dados pública;
- identificar características presentes nos sinais de EEG de portadores de DN, avaliando sua utilidade como parâmetro de identificação da respectiva DN;
- realizar testes com os portadores de DN, extraíndo seu padrão de distribuição da potência espectral;
- confrontar os padrões de distribuição de potência espectral entre os portadores e não-portadores de DA;
- estabelecer correlação que permita identificar os portadores e não-portadores de DA, viabilizando definição da hipótese diagnóstica sua aplicação como ferramenta de auxílio diagnóstico da doença.

1.4 Organização deste trabalho

Este trabalho está organizado em seis capítulos, dois apêndices e um anexo. As referências se encontram nas páginas finais. A seguir, um resumo dos capítulos seguintes.

Capítulo 2. Faz uma revisão sistemática da literatura, posicionando-o quanto ao estado-da-arte.

Capítulo 3. Faz uma breve abordagem sobre o Sistema Nervoso Central humano e seus conceitos mais diretamente relacionados à concepção de redes neurais artificiais.

Capítulo 4. Aborda a aquisição de sinais biológicos, com os detalhes que envolvem o seu processamento.

Capítulo 5. Apresenta a implementação da Rede Neural Adaptativa (RNAA), que tem como objetivo classificar portadores e não-portadores da doença de Alzheimer, inclusive em seu estágio inicial. Aplica-se uma estratégia para otimizar a sua performance, relacionada à dinâmica de inserção dos dados na etapa de treinamento. Testes e simulações com sinais de EEG são realizados na validação da estratégia, com os resultados avaliados e discutidos.

Capítulo 6. Apresenta uma breve sinopse do trabalho desenvolvido, com conclusão e discussões contextualizadas, propostas de aprimoramentos, sugestões de complemento ao trabalho desenvolvido e um resumo dos trabalhos publicados.

Apêndice A. Amostras do Treinamento e Validação.

Apêndice B. Janelas gráficas do teste.

Anexo A. Referência da Base de Dados OpenNeuro.

*"O caráter de uma pessoa é
expresso por aquilo que ela faz
quando acha que ninguém está
vendo."*

John Wooden.

Capítulo 2

Revisão Sistemática da Literatura

Esta Revisão Sistemática da Literatura - RSL tem como propósito contextualizar o trabalho ora apresentado, no universo científico onde se encontra. Ela contempla sua contemporaneidade. Ao apresentar pesquisas correlatas, estabelece uma linha de continuidade investigativa, seja trazendo novos achados, seja fortalecendo os previamente encontrados, através de uma nova abordagem técnica ou aplicação (OKOLI; SCHABRAM,2015; FERENHOF; FERNANDES,2016).

Assim, neste capítulo, são apresentados resumos dos aspectos quantitativo e qualitativo de outros trabalhos, sob algum aspecto correlacionados com o tema principal aqui abordado. Essa RSL permite identificar a sintonia deste trabalho com o atual estado-da-arte.

2.1 Ferramentas aplicadas nesta RSL

As principais ferramentas aplicadas nesta RSL foram os mecanismos de busca, com as respectivas bases gerenciadas pelo IEEE, Science Direct, Springer, PUB-MED, PMC e ACM. O mecanismo de busca Google Scholar também foi usado. O gerenciamento de referências foi realizado com o Zotero®, Versão 6.0.36.

Como diversas referências se encontram disponíveis em múltiplas plataformas, a pesquisa realizada nessas bases traz resultados iguais, sendo necessário a filtragem de duplicatas. Essa filtragem foi realizada através das opções de refinamento, no

ambiente de trabalho do Zotero ®.

2.2 Palavras-chave

Um trabalho acadêmico deve zelar pela definição de suas palavras-chave, uma vez que as mesmas devem ser capazes de resumir os aspectos mais importantes da abordagem realizada na pesquisa. Elas são aplicadas no processo de indexação, pois facilitam a sua localização através dos mecanismos de busca usados por pesquisadores durante o desenvolvimento de seus trabalhos. Assim as palavras-chave são de fundamental importância no processo de divulgação de um trabalho no meio científico (KITCHENHAM,2004;KITCHENHAM et al.,2010).

2.2.1 Escolha das palavras-chave

Para viabilizar o alcance dos objetivos de uma RSL, faz-se necessário limitar o imenso universo de fontes disponíveis para pesquisa. Para cumprir esta tarefa, é importante elaborar perguntas que ajudem na definição das *strings* de busca. Além disso, estabelecer um intervalo de busca mais recente possível, na média de 5 a 10 anos, conforme disponibilidade da base de pesquisa. No contexto deste trabalho, a sequência lógica que orientou a definição das palavras-chave, usadas para compor as *strings* de busca aplicadas nas pesquisas das bases foi:

- Quais os trabalhos que aplicam Redes Neurais Artificiais (RNAs), nos últimos 10 anos?
- Das RNAs aplicadas a sinais biológicos, quais são as relacionadas a sinais de EEG?
- Das RNAs aplicadas a EEG, quais são aplicadas para diagnósticos de doenças neurológicas?
- Das RNAs aplicadas ao diagnóstico de doenças neurológicas, quais são voltadas para a Doença de Alzheimer?

Com as respostas a essas perguntas, ficaram definidas as seguintes palavras-chave para composição das *strings* de busca aplicadas nas pesquisas em cada uma das bases: Rede neural artificial, diagnóstico da doença de Alzheimer, doença neurológica e reconhecimento de padrão em EEG. Para obter o resultado mais apropriado, as palavras-chave foram traduzidas para o idioma inglês, por ser este o idioma mais usado na publicação de trabalhos científicos. Assim, ficaram definidas respectivamente como: *Artificial neural network*, *Alzheimer’s disease diagnosis*, *neurological disease*, *EEG pattern recognition*.

2.3 Seleção de referências

A seleção de referências foi realizada através de pesquisa em bases de dados especializadas, sendo dividida em 3 etapas: Identificação, Triagem e Elegibilidade (MARIANO; ROCHA,2017).

2.3.1 Identificação

As bases IEEE, Science Direct, Springer, PUBMED, PMC e ACM foram usadas. As palavras-chave escolhidas permitiram a composição de uma *string* de busca especificamente relacionada com o trabalho desenvolvido: “*Artificial neural network for Alzheimer’s disease diagnosis from EEG signals*”.

Essa sentença de busca aliada aos filtros disponíveis nas bases pesquisadas viabilizou a obtenção de um conjunto de referências mais delimitado e em sintonia com o trabalho. Os resultados das pesquisas iniciais em cada base são apresentados nas respectivas tabelas, abaixo apresentadas:

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer’s disease diagnosis	56	2015 até 2024
Artificial Neural Network AND neurological disease	63	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	2	2015 até 2024

Tabela 2.1: IEEE - Pesquisa inicial.

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer's disease diagnosis	197	2015 até 2024
Artificial Neural Network AND neurological disease	178	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	834	2015 até 2024

Tabela 2.2: Science Direct - Pesquisa inicial.

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer's disease diagnosis	92	2015 até 2024
Artificial Neural Network AND neurological disease	43	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	313	2015 até 2024

Tabela 2.3: Springer - Pesquisa inicial.

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer's disease diagnosis	17	2015 até 2024
Artificial Neural Network AND neurological disease	2	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	1	2015 até 2024

Tabela 2.4: Pubmed - Pesquisa inicial.

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer's disease diagnosis	14	2015 até 2024
Artificial Neural Network AND neurological disease	58	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	6	2015 até 2024

Tabela 2.5: PMC - Pesquisa inicial.

Palavras-chave	Resultado	Intervalo
Artificial Neural Network AND Alzheimer's disease diagnosis	7	2015 até 2024
Artificial Neural Network AND neurological disease	7	2015 até 2024
Artificial Neural Network AND EEG pattern recognition	2	2015 até 2024

Tabela 2.6: ACM - Pesquisa inicial.

O resultado da pesquisa inicial apresentou 1892 referências. Nesse resultado, foram aplicados outros filtros disponíveis nas bases de origem, além de inspeção manual, a saber:

- *String* genérica presente no título ou no resumo (*abstract*);
- remoção manual de referências não relacionadas ao tema da pesquisa, mas presentes na lista de resultados, por possuírem uma ou mais das *strings* genéricas em seu texto. São aquelas que não se enquadram com o trabalho, por se tratarem de pesquisas voltadas para outras áreas, como agricultura, pecuária, mercado financeiro;

- manutenção de referências da área de Inteligência artificial em medicina na base Science Direct.

Após aplicação desses filtros, a lista ficou reduzida a 114 referências, ou seja, uma redução de 94%. As 114 referências filtradas foram submetidas à próxima etapa, a de triagem.

2.3.2 Triagem

A triagem realizada sobre o resultado da etapa anterior envolveu a leitura parcial das referências, especialmente no resumo, no sentido de identificar a existência ou não de relação entre a sua abordagem e o trabalho aqui proposto. Os critérios usados nessa triagem foram os seguintes:

- Descarte daquelas cujos objetivos não eram de viabilizar o diagnóstico da doença de Alzheimer;
- descarte daquelas cujo arquivo pdf não se encontra acessível;
- descarte daquelas que consistem em capítulos de livro, manuais técnicos ou similares;
- descarte daquelas que, apesar de possuírem os mesmos objetivos, seus métodos não permitem estabelecer correlação com o aplicado neste trabalho.

Assim, foram identificados 49 trabalhos relacionados ao tema, sobre os quais foram aplicados critérios de elegibilidade, com o propósito de identificar os mais pertinentes para composição desta revisão, conforme a etapa de elegibilidade, apresentada a seguir.

2.3.3 Elegibilidade

Esta etapa é destinada à escolha das referências para composição da RSL. Os critérios são aplicados mediante verificação de cada uma, através de sua leitura para

identificação de correlação com o trabalho proposto. São observados aspectos relacionados aos métodos usados em cada referência, pelos quais cada uma é classificada numa escala de 1 a 10, correspondente ao somatório dos respectivos graus de relevância, conforme a Tabela 2.7, abaixo:

Aspecto	Grau de relevância (GR)
Método é empregado para diagnóstico da DA	3
Método aplica sinal de EEG como entrada	3
Método aplica rede neural artificial	2
Método aplica sinal de imagem como entrada	1
Apresenta os resultados	2

Tabela 2.7: Grau de relevância dos aspectos avaliados.

O critério estabelecido para inclusão de uma referência na RSL foi possuir somatório dos GR (SGR) maior ou igual a 7 ($SGR \geq 7$). Assim, embora todas as referências constantes nesta etapa possuam algo relacionado com este trabalho, pelo critério estabelecido foram selecionadas 10 dentre as 49 iniciais. A Tabela 2.8 relaciona as referências selecionadas, com uma breve descrição das respectivas abordagens.

2.4 Estado da Arte

A doença de Alzheimer – DA se caracteriza pela perda progressiva e irreversível da memória e capacidade cognitiva. Somente no Brasil, possui mais de 1 milhão e duzentos mil portadores, com estimativa de aumento maior que 90%, até 2030, considerando-se que anualmente são diagnosticados mais de 100 mil novos casos (NITRINI et al.,2005). Sua prevalência tem sido, há mais de 25 anos, um dos principais estímulos às pesquisas na área. A DA acomete a população idosa a partir dos 67 anos, na grande maioria dos casos. Quando ocorre antes dos 65 anos de idade, é classificada como Alzheimer precoce (TRUZZI; LAKS,2005). significativamente a qualidade de vida das pessoas atingidas, com radicais mudanças na rotina das famílias (GROSSI et al.,2005; RODRIGUES et al.,2020). Na medida em que seja diagnosticada somente após apresentar os primeiros sintomas mais evidentes, a conduta terapêutica para seu acompanhamento pouco consegue, no sentido de retardar

a evolução vertiginosa da doença. Ela corresponde a 60% dos casos confirmados de demências, sendo a principal causa da dependência funcional e mortalidade na população idosa, associada a doenças cardiovasculares e diabetes. A DA está associada a uma redução da expectativa de vida de 67%, quando diagnosticada na faixa etária dos 65 anos; e de 39%, quando na faixa etária dos 90 anos (TEIXEIRA et al.,2015).

O diagnóstico antecipado da DA é almejado por muitos pesquisadores em todo o mundo (BERTÈ et al.,2014; GORJI; HADDADNIA,2015; ISLAM; ZHANG,2018; SOLANO-ROJAS; VILLALÓN-FONSECA; MARÍN-RAVENTÓS,2020). Isto ocorre por diversas razões, entre as quais pode-se destacar o retardo de seus sintomas mais severos, como a perda de memória, confusão mental e o comprometimento do senso de direção (MA et al.,2014).

Neste sentido, muitos pesquisadores trabalharam na identificação de métodos e aplicação de ferramentas capazes de agilizar o diagnóstico da DA. Almir Aljovic (ALJOVIĆ; BADNJEVIĆ; GURBETA,2016) desenvolveu uma rede neural artificial para receber dados relativos a biomarcadores da DA, a partir de 80 indivíduos, sendo 45 portadores de DA e 35 não-portadores. O uso de biomarcadores para identificação da DA foi estimulado nos últimos 10 anos. Inicialmente, a prática comum era o uso de um único biomarcador. Contudo, novos progressos evidenciaram que o uso de múltiplos biomarcadores 31 simultaneamente é mais vantajoso, pois assim ocorre a identificação de mais informações que podem ser associadas a doença.

Esta RSL foi orientada de modo a identificar estudos voltados à aplicação para o diagnóstico da DA, com preferência àqueles que aplicam os mesmos métodos e recursos usados no desenvolvimento deste trabalho. Considerando, ainda, que a existência total desses pré-requisitos não tenha sido encontrada, foram selecionados aqueles que as contemplam parcialmente e com os quais se possa estabelecer uma relação para análise qualitativa dos resultados aqui obtidos.

Referência	Abordagem
(GKENIOS et al.,2022)	Aplica EEG e redes neurais recorrentes para diagnóstico da DA e CCL. Apresentou resultados promissores na identificação de casos moderados a graves de Alzheimer.
(ALVES et al.,2022)	Empregou conectividade funcional de EEG e técnicas de aprendizagem profunda para diagnosticar automaticamente doenças cerebrais, incluindo a DA. Os resultados indicaram capacidade de classificação de pacientes com Alzheimer, nos estágios graves da doença.
(KLEPL et al.,2023)	Propõe uma rede neural convolucional de grafos para diagnosticar DA com base em dados de EEG, com previsões acompanhada de explicações interpretáveis.
(HONG et al.,2023)	Apresenta um modelo de inteligência artificial utilizando EEG para classificar indivíduos sem demência e com DA nos estados graves, alcançando uma acurácia de 87,67%, sensibilidade de 88,89% e especificidade de 87,61%.
(JEONG et al.,2023)	Apresenta um classificador baseado em QEEG e TabNet para distinguir entre Alzheimer e doença de corpos de Lewy, contribuindo para diagnósticos diferenciais mais precisos.
(XIA et al.,2023)	método para diagnosticar a DA utilizando RNA convolucional piramidal profunda, baseada em EEG. O método demonstrou eficácia na identificação de casos moderados e graves da doença.
(WAGH; VARATHARAJAH,2020)	Aplica uma RNA convolucional de grafos guiada por domínio para melhorar o diagnóstico de DNs com base em EEG. O modelo se mostrou eficaz na detecção de estágios moderados a graves da DA.
(BABILONI et al.,2017)	Utilizou RNA para classificar indivíduos saudáveis e pacientes com DA, com base nas fontes corticais dos ritmos do EEG em estado de repouso. Embora tenha alcançado uma precisão de classificação de 75,5%, o estudo não diferenciou entre os diferentes estágios da doença.
(LIZIO et al.,2019)	Aplica características derivadas do EEG em estado de repouso para classificar pacientes com DA em comparação com indivíduos saudáveis. Obteve boa precisão na distinção entre os grupos, mas não abordou a diferenciação entre os estágios da doença.
(CASSANI et al.,2018)	Analizou o uso do EEG em estado de repouso para o diagnóstico e avaliação da progressão da DA. Destaca que, embora o EEG seja útil para diferenciar entre indivíduos saudáveis e portadores DA, há limitações na sua capacidade de distinguir entre os diferentes estágios da doença.

Tabela 2.8: Referências selecionadas

*"A cada minuto temos a
oportunidade de mudar tudo para
melhor!"*

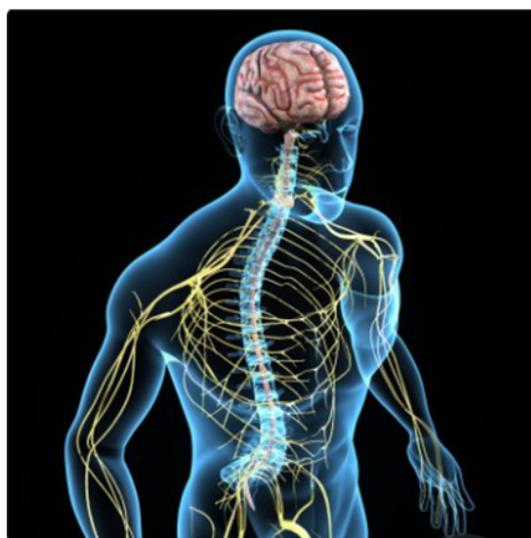
Chico Xavier.

Capítulo 3

Sistema Nervoso Humano e Rede Neural Artificial

Na espécie humana, o cérebro é o principal órgão do Sistema Nervoso Central (SNC), que é apresentado na Figura 3.1.

Figura 3.1: Sistema nervoso central.



Fonte: (DEPOSITPHOTOS,2025,SNC).

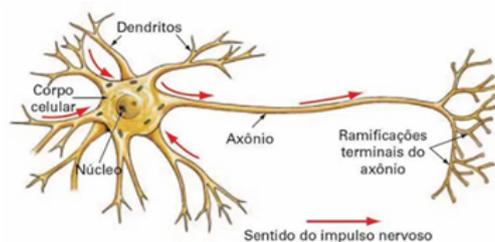
O SNC é formado por células especiais, denominadas de neurônios. Os neurônios se organizam, formando uma rede complexa, através da qual se comunicam. Neste capítulo, são apresentados aspectos do SNC humano, para permitir melhor analogia entre o mesmo e as Redes Neurais Artificiais (RNAs), que são por ele inspiradas

(GUPTA; JIN; HOMMA,2004).

3.1 O neurônio biológico humano

A Figura 3.2 apresenta a ilustração de um neurônio biológico humano, destacando sua composição e o sentido do impulso nervoso através de suas vias de entrada e saída de informação, os dendritos e o axônio, respectivamente (SILVERTHORN,2017). Os neurônios biológicos humanos se conectam uns aos outros,

Figura 3.2: Neurônio biológico humano.



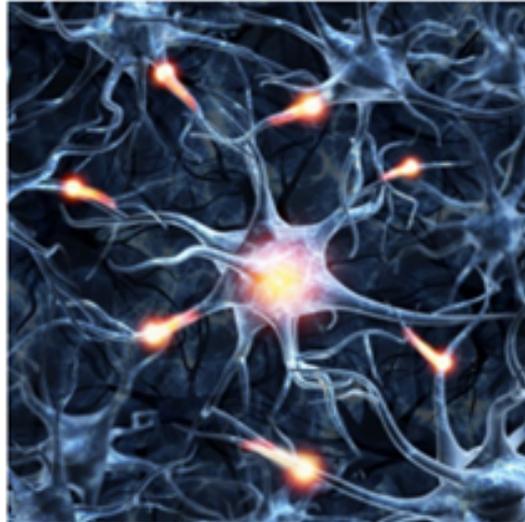
Fonte: (DEPOSITPHOTOS,2025,Neurônio).

formando redes, que operam como unidades funcionais. Eles se comunicam através de mecanismos próprios, denominados de sinapse. A Figura 3.3 apresenta neurônios em conexão, formando uma rede neural biológica, através de suas sinapses (SILVERTHORN,2017).

Essas redes neurais se conectam umas às outras, formando um grande e complexo sistema responsável por todas as ações e reações executadas pelos seres humanos (KANDEL; SCHWARTZ; JESSELL,2013).

Nas próximas seções, verifica-se como são formadas as diferenças de potencial elétrico no corpo humano e o mecanismo de sua propagação. Ao final, as características relativas ao EEG são destacadas, uma vez que ele é a matéria-prima básica para produção deste trabalho.

Figura 3.3: Neurônios conectados em rede.

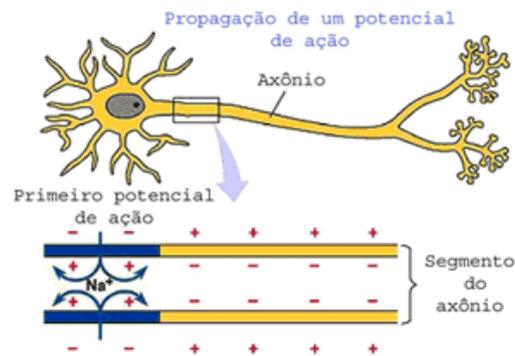


Fonte: (DEPOSITPHOTOS,2025,Neurônios em rede).

3.2 O potencial elétrico humano

Os potenciais elétricos encontrados ao longo do corpo humano são originados a nível celular. São decorrentes das diferentes concentrações iônicas dentro e fora da célula. A membrana celular separa altas concentrações de íons de potássio e baixas concentrações de íons de sódio entre os meios intra e extracelular, respectivamente. São estas diferentes concentrações que originam o potencial elétrico, como mostra a Figura 3.4 (SCHAUF; MOFFETT; MOFFETT,1993). A Figura 3.5 ilustra as fases

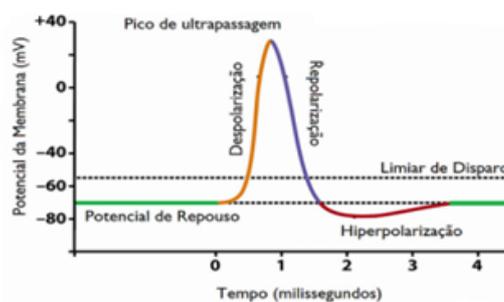
Figura 3.4: Potencial de ação celular.



Fonte: (ALBERTS,2010,Potencial de ação).

de existência de um potencial de ação, no domínio do tempo. Quando um neurônio recebe um estímulo excitatório de outro neurônio, sua membrana é despolarizada, resultando na abertura de canais dependentes de tensão, que favorecem à entrada de sódio. Assim, a membrana é mais despolarizada e, quando chega em um potencial específico, o limiar de disparo, a probabilidade de ocorrer um potencial de ação é de aproximadamente 50%. O potencial de ação só ocorre quando a membrana é despolarizada além do limiar de disparo (SCHAUF; MOFFETT; MOFFETT,1993).

Figura 3.5: Duração do potencial de ação.



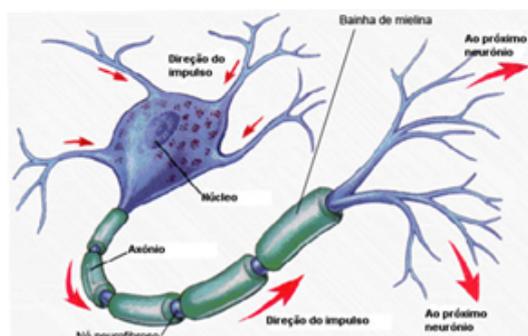
Fonte: (ALBERTS,2010, Duração do potencial de ação).

Na despolarização, canais de sódio (Na) são abertos, permitindo o fluxo de sódio para o interior da célula. No pico de ultrapassagem, o neurônio se torna positivo em relação ao ambiente extracelular. Na repolarização, canais de potássio (K) dependentes de tensão são abertos, permitindo o fluxo de K^+ para o meio extracelular. Como esses canais abrem um pouco atrasados depois da despolarização, são chamados de canais retificadores atrasados. Eles recebem esse nome por permitir um maior fluxo de íons apenas em uma direção. Na hiperpolarização, o neurônio fica mais negativo que o potencial de repouso da membrana, devido a alta permeabilidade que a membrana apresenta ao potássio, pela presença dos canais adicionais de potássio anteriormente abertos, além daqueles já existentes naturalmente. Depois desta fase, o potencial de repouso da membrana é restaurado aos poucos (KANDEL; SCHWARTZ; JESSELL,2013).

O potencial de ação é imprescindível para que ocorra comunicação entre as células nervosas do corpo, os neurônios. Essa comunicação se estabelece de forma

eletroquímica. Os neurônios transmitem potencial de ação em um sentido único, através dos canais iônicos que se formam entre os neurotransmissores e receptores. Os dendritos conduzem o impulso na direção do corpo celular, enquanto o axônio, em direção às extremidades, ou seja, para longe do corpo celular, como ilustra a Figura 3.6 (KANDEL; SCHWARTZ; JESSELL,2013;BEAR; CONNORS; PARADISO,2015).

Figura 3.6: Sentido do impulso nervoso.



Fonte: (ALBERTS,2010, Sentido do impulso nervoso).

3.3 Doenças neurológicas

As doenças que atingem o SNC são consequências de processos neurodegenerativos, que provocam disfunções e morte de regiões do cérebro, provocando um quadro tecnicamente denominado de demência. Conforme a causa, existem diferentes tipos de demência. As mais conhecidas são: a doença de Alzheimer (DA), a demência vascular (DVa), causada por acidente vascular cerebral isquêmico ou hemorrágico, a demência fronte-temporal (DFT) e a doença de Parkinson (DP) (HAMPEL et al.,2010).

O diagnóstico dessas doenças necessita de uma quantidade significativa de dados, os quais são obtidos através de exames de diversos tipos: fisiológicos, laboratoriais, de imagem, clínicos, comportamentais, entre outros. Dentre esses exames, o EEG se destaca como um dos mais relevantes, pois os sinais nele registrados refletem diretamente a atividade neuronal no momento de sua aquisição. Por sua alta sensi-

bilidade a alterações funcionais do SNC, o EEG é amplamente utilizado na detecção e monitoramento de condições como epilepsia, encefalopatias, distúrbios do sono e alterações agudas do estado de consciência. Além disso, trata-se de um exame não invasivo, de baixo custo relativo, o que o torna uma ferramenta indispensável na prática clínica neurológica e em pesquisas neurocientíficas (NIEDERMEYER; SILVA,2011).

3.3.1 Aplicação de EEG no diagnóstico e tratamento de doenças neurológicas

A análise computadorizada de sinais de EEG tem sido empregada para análise de distúrbios do sono (RODRIGUES et al.,2002), distúrbios do espectro autista (AHMADLOU; ADELI; ADELI,2010), na análise de evolução da Doença de Alzheimer (GILI et al.,2011), no auxílio à implementação de interfaces cérebro-máquina para tratamento de portadores de deficiência motora (FREITAS,2017), entre outros.

No papel de um biomarcador neurofisiológico, um EEG pode apontar diferentes condições fisiológicas e patológicas, tais como os efeitos de uma demência sobre as funções corticais. Considerando isso, o EEG pode ser usado não apenas como ferramenta de diagnóstico após o acometimento, mas também se antecipar a ele (HAMPEL et al.,2014). Alguns estudos mostram que o EEG pode ser aplicado para detecção de doenças neurológicas nos seus estados iniciais (AL-QAZZAZ et al.,2014; PETROSIAN et al.,2001).

Nesse contexto, a RNA apresentada no Capítulo 5 deste trabalho se propõe a contribuir no auxílio ao processo diagnóstico da doença de Alzheimer.

3.3.2 Métodos aplicados para diagnóstico da doença de Alzheimer

Atualmente, diversos métodos são empregados no diagnóstico da Doença de Alzheimer, incluindo exames de neuroimagem como a ressonância magnética (MRI),

tomografia por emissão de pósitrons (PET), EEG e, mais recentemente, técnicas ópticas, como a espectroscopia no infravermelho próximo (NIRS). Esses métodos permitem a detecção de alterações estruturais, funcionais e bioquímicas associadas à progressão da doença, contribuindo para uma avaliação mais precisa e precoce. Entretanto, muitos desses exames demandam equipamentos de alto custo e infraestrutura especializada, o que limita seu acesso em regiões com poucos recursos, atrasando significativamente o diagnóstico clínico em uma parcela considerável da população afetada pela DA. Infelizmente, boa parte desses métodos é de acesso difícil à parcela significativa das pessoas afetadas pela DA, o que provoca o atraso no seu diagnóstico (LIVINGSTON et al.,2020; JIANG et al.,2022; BABILONI et al.,2020).

3.3.3 O diagnóstico da doença de Alzheimer através de sinais de EEG

O sinal de EEG é uma ferramenta valiosa para a análise e compreensão da atividade cerebral, especialmente no contexto de doenças neurológicas como a doença de Alzheimer. Ele reflete, em tempo real, a dinâmica elétrica dos neurônios corticais, o que o torna adequado para detectar alterações sutis na função cerebral. O espectro de frequência do EEG é tradicionalmente segmentado nas bandas delta δ (0,5–4 Hz), teta θ (4–8 Hz), alfa α (8–13 Hz), beta β (13–30 Hz) e gama γ (> 30 Hz), que estão intimamente relacionadas a diferentes estados mentais e comportamentais. Essas bandas refletem padrões distintos de sincronização neuronal, que são significativamente afetados por processos neurodegenerativos (BABILONI et al.,2020).

Indivíduos com DA apresentam uma diminuição nas atividades de alta frequência (alfa e beta) e um aumento relativo nas de baixa frequência (delta e teta), o que indica disfunção cortical progressiva. Essa característica torna o EEG uma ferramenta promissora para o rastreamento, diagnóstico precoce e monitoramento da progressão da doença (CUESTA et al.,2021).

Ressalte-se que durante a aquisição do EEG, a atividade cerebral pode ser registrada em diferentes contextos experimentais ou clínicos, tais como: estado de

repouso com olhos fechados; tarefa cognitiva de memória; execução de comandos motores simples, como por exemplo abrir e fechar as mãos; e estimulação visual ou auditiva, com propósitos específicos (SMAILOVIC; JELIC,2019).

A escolha da tarefa pode influenciar significativamente a distribuição das bandas de frequência e sua interpretação clínica, sendo fundamental na identificação de padrões característicos da DA. Tanto a DA quanto o Comprometimento Cognitivo Leve (CCL) apresenta reflexos nos sinais de EEG (BAKER et al.,2008), com aumento de atividade nas bandas teta e delta, assim como declínio nas bandas alfa e beta (DAUWELS; VIALATTE; CICHOCKI,2010), o que foi ratificado por estudos posteriores, a exemplo de (CUESTA et al.,2021).

Na prática clínica, o processo diagnóstico da DA e CCL é normalmente realizado através de alguns testes que sempre envolvem a análise do histórico familiar, testes cognitivos, além de exames de imagens e outros afins (TSOI et al.,2015). Isso tudo requer um tempo considerável, o que provoca uma conclusão diagnóstica muitas vezes tardia, com sofrimentos que atingem todos os envolvidos no processo: paciente, familiares e as pessoas do círculo de relacionamento mais próximo.

3.3.4 Avaliação do processo diagnóstico

Para avaliar a qualidade de exames usados no diagnóstico de doenças, existem parâmetros estatísticos fundamentais que ajudam a determinar sua precisão e confiabilidade. Esses parâmetros são amplamente usados para interpretar o desempenho de exames em termos de sensibilidade, especificidade e outros indicadores importantes. Os principais incluem: Sensibilidade, Especificidade, Valor Preditivo Positivo, Valor Preditivo Negativo, Acurácia e Razão de Verossimilhança (ALTMAN; BLAND,1994).

Sensibilidade (S)

A sensibilidade mede a capacidade de um teste de identificar corretamente os indivíduos com a doença. Em outras palavras, é a proporção de resultados positivos

verdadeiros entre todos os indivíduos que realmente possuem a doença.

$$S = \frac{VP}{VP + FN}, \text{ onde } S \text{ é Sensibilidade, } VP \text{ é Verdadeiro Positivo e } FN \text{ é Falso Negativo.} \quad (3.1)$$

Um diagnóstico com alta sensibilidade garante que quase todos os casos da doença sejam identificados, com a minimização dos falsos negativos.

Especificidade (E)

A especificidade mede a capacidade de um teste identificar corretamente os indivíduos que não tem a doença. É a proporção de resultados negativos verdadeiros entre todos os indivíduos sem a doença.

$$E = \frac{VN}{VN + FP}, \text{ onde } E \text{ é Especificidade, } VN \text{ é Verdadeiro Negativo e } FP \text{ é Falso Positivo.} \quad (3.2)$$

Um diagnóstico com alta especificidade reduz o número de falsos negativos.

Acurácia (A)

A acurácia mede a proporção de todos os diagnósticos com resultados corretos (positivos e negativos) entre todos os diagnósticos realizados (NTD).

$$A = \frac{VP + VN}{NTD}, \text{ onde } A \text{ é Acurácia, } VN \text{ é Verdadeiro Negativo e } VP \text{ é Verdadeiro Positivo.} \quad (3.3)$$

A acurácia dá uma ideia da eficiência do processo diagnóstico.

Valor Preditivo Positivo (VPP)

É a probabilidade de que um indivíduo com um resultado positivo no teste realmente tenha a doença.

$$VPP = \frac{VP}{VP + FP}, \text{ onde } VP \text{ é Verdadeiro Positivo e } FP \text{ é Falso Positivo.} \quad (3.4)$$

Um VPP alto é desejável para confirmar um diagnóstico quando o teste resulta positivo. Sua eficácia depende da prevalência da doença na população.

Valor Preditivo Negativo (VPN)

É a probabilidade de que um indivíduo com um resultado negativo no teste realmente não tenha a doença, ou seja, a proporção de resultados negativos verdadeiros entre todos os indivíduos sem a doença.

$$\text{VPN} = \frac{\text{VN}}{\text{VN} + \text{FN}}, \text{ onde VN é Verdadeiro Negativo e FN é Falso Negativo. } \quad (3.5)$$

Um diagnóstico com o VPN alto é importante para excluir a presença da doença em indivíduos com diagnóstico negativo.

Razão de Verossimilhança (RV)

Calculada nos dois tipos de resultados: o positivo (RV+) e o negativo (RV-).

O RV+: Indica quantas vezes é mais provável que um resultado positivo seja encontrado em uma pessoa com a doença que em uma pessoa sem a doença.

$$\text{RV+} = \frac{\text{S}}{1 - \text{E}}, \text{ onde S é Sensibilidade e E é Especificidade. } \quad (3.6)$$

O RV-: Indica quantas vezes é mais provável que um resultado negativo seja encontrado em uma pessoa sem a doença que em uma pessoa com a doença.

$$\text{RV-} = \frac{1 - \text{S}}{\text{E}}, \text{ onde S é Sensibilidade e E é Especificidade. } \quad (3.7)$$

3.3.5 Critérios para hipótese diagnóstica

O diagnóstico da Doença de Alzheimer por meio da análise de sinais de EEG é um desafio considerável, dada a complexidade inerente às alterações neurofisiológicas causadas pela doença. Essas alterações afetam de maneira sutil e variada os padrões de oscilação cerebral, tornando a simples inspeção visual dos sinais ineficaz na de-

tecção precoce da DA. Essa dificuldade decorre da natureza multifatorial e não-linear dos sistemas fisiológicos envolvidos, cujas interações geram sinais com características tanto determinísticas quanto estocásticas, frequentemente mascaradas por ruídos de diferentes origens (MORETTI,2022).

Para uma caracterização robusta do EEG em indivíduos com DA, é fundamental empregar abordagens quantitativas que envolvam medidas como a densidade espectral de potência, a coerência interregional e outros índices de conectividade funcional. Tais métodos permitem captar alterações sutis na dinâmica cerebral, associadas à disfunção sináptica e à perda progressiva de conectividade funcional, que são características marcantes da doença de Alzheimer em seus estágios iniciais (KUMRAL; ŞAHIN et al.,2021).

3.4 Caracterização do sinal de EEG

Para caracterizar o sinal de EEG com o propósito de classificação, dois parâmetros se mostram bem úteis: a densidade espectral de potência, que permite identificar e quantificar a distribuição da energia do sinal ao longo das diferentes bandas de frequência; e a coerência, que mede a correlação linear entre dois sinais em função da frequência, sendo muito usada na análise de sinais de EEG para investigar a conectividade funcional entre regiões cerebrais (TEPLAN,2002;CASSANI et al.,2018).

3.4.1 Densidade espectral de potência

A densidade espectral de potência (dsp) representa a distribuição da potência de um sinal no seu espectro de frequências. No contexto de EEG, ela indica quanto de energia está presente em suas diferentes bandas de frequência (delta δ , teta θ , alfa α , beta β , gama γ), o que é fundamental para análise neurológica, em que é usada para identificar oscilações cerebrais, características associadas a estados mentais ou condições neurológicas (KRAMER,2021).

No Sistema Internacional (SI), a unidade padrão da dsp é Watt por Hertz (W/Hz),

sendo aplicada para sinais em áreas onde a energia pode ser diretamente convertida em potência elétrica ou mecânica como, por exemplo, nas áreas de áudio e telecomunicações.

No contexto de EEG, os sinais medidos correspondem a tensões elétricas registradas, na grande maioria das vezes, diretamente do couro cabeludo, através de eletrodos. Esses sinais não medem potência diretamente, mas sim diferenças de potencial elétrico bem pequenas, na ordem de microvolts (μV). Sendo o sinal definido apenas em termos de tensão, sua potência é considerada em termos do seu quadrado. Sendo assim, para sinais de EEG, a unidade de medida usada para densidade espectral de potência é o microvolt ao quadrado por Hertz ($\mu V^2/Hz$).

No cálculo da densidade de potência para sinais discretos, como é o caso do sinal de EEG deste trabalho, usa-se:

$$S_x(f) = \frac{1}{N \cdot F_s} \left| \sum_{n=0}^{N-1} x[n] e^{-j2\pi f n / F_s} \right|^2 \quad (3.8)$$

Sendo:

$S_x(f)$: Sinal densidade de potência (dsp)

$x[n]$: sinal de EEG amostrado;

N : número total de amostras;

F_s : frequência de amostragem (Hz)

f : frequência para a qual a dsp é estimada.

No Matlab, a função apresentada abaixo é aplicada para estimar a densidade espectral de potência (DSP) do sinal de EEG. Ela é baseada no método de Welch, que divide o sinal em janelas sobrepostas, calcula a transformada de Fourier (FFT) de cada janela, e depois obtém a média.

```
[S, f] = pwelch(x[n], W, olap, nfft, Fs);
```

Sendo:

S : vetor da densidade de potência (DSP) estimada;

f : vetor de frequências da DSP estimada;

$x[n]$: sinal de EEG amostrado;

W : tamanho da janela usada para dividir o sinal;

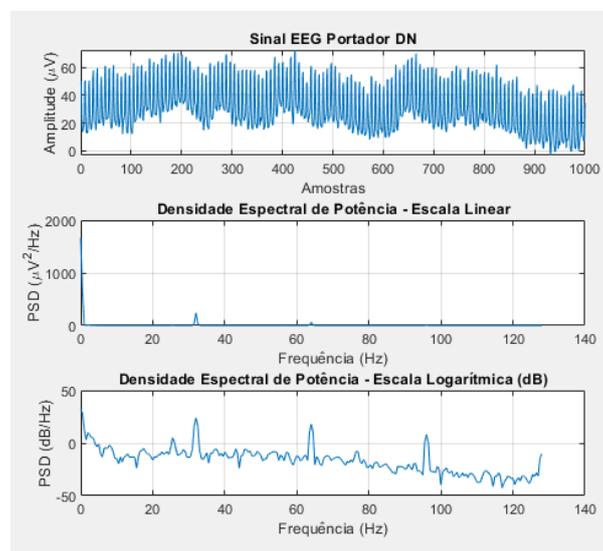
$olap$: amostras de sobreposição entre janelas;

$nfft$: número de pontos da FFT;

F_s : frequência de amostragem do sinal EEG (Hz).

A Figura 3.7, apresenta a amostragem de um sinal de EEG de um portador de DA, com os gráficos de sua densidade espectral de potência, estimada nas escalas linear e logarítmica.

Figura 3.7: Sinal EEG e sua densidade espectral de potência.



Fonte: (Acervo do autor)

No EEG de portadores de DA, observa-se uma variação no ritmo dos padrões das ondas cerebrais delta δ , teta θ , alfa α , beta β , que altera a distribuição dessa densidade, ocorrendo aumento nas bandas de baixa frequência, δ e teta θ , assim como uma redução nas bandas de alta frequência, alfa α e beta β .

A identificação dessa variação, seguido do cálculo de sua potência espectral é, então, comparada com dados de referência (DR), que são relativos a EEG de não-portadores de DA, previamente armazenados. O resultado dessa comparação, quando discrepante, é usada como subsídio para fundamentar a hipótese diagnóstica, relativa a tais portadores de DA.

3.4.2 Coerência

Aplicada a sinais de EEG, mede o grau de sincronismo entre as regiões dos dois hemisférios do cérebro. Nos portadores da DA, observa-se uma redução da coerência, principalmente nas bandas alfa α e beta β , o que pode ser um indicativo da perda de capacidade cognitiva (JELLES et al.,2008). Nos sinais de EEG, ela pode ser medida aplicando-se uma técnica de análise, que envolve o cálculo da correlação entre dois sinais em diferentes frequências, ou seja, é a medida da sua covariância ao longo do seu espectro. Ela é medida numa escala de 0 a 1, onde 0 indica ausência de coerência e 1 indica coerência completa.

Para o cálculo da coerência entre dois sinais, aplica-se a transformada de Fourier cruzada. Nessa técnica, os sinais são divididos em segmentos curtos e a transformada de Fourier é aplicada a cada segmento. Em seguida, a coerência é calculada como a razão entre a densidade espectral cruzada dos dois sinais e a média da densidade espectral individual (MATHWORKS,2023;NUNEZ; SRINIVASAN,2006).

Matematicamente, a coerência entre dois sinais $x(t)$ e $y(t)$ na frequência f é definida como:

$$C_{xy}(f) = \frac{|\mathbb{E}[X(f)Y^*(f)]|^2}{\mathbb{E}[|X(f)|^2] \cdot \mathbb{E}[|Y(f)|^2]} \quad (3.9)$$

Onde:

- $C_{xy}(f)$: Coerência entre os sinais $x(t)$ e $y(t)$ na frequência f ;
- $X(f)$: Transformada de Fourier do sinal $x(t)$;
- $Y(f)$: Transformada de Fourier do sinal $y(t)$;
- $Y^*(f)$: Conjugado complexo de $Y(f)$;
- $\mathbb{E}[\cdot]$: Valor esperado (média estatística, por exemplo, entre janelas segmentadas do sinal);
- $|X(f)|^2$: Densidade espectral de potência do sinal $x(t)$;

- $|Y(f)|^2$: Densidade espectral de potência do sinal $y(t)$.

Ou seja, expressa em termos de densidade espectral é:

$$C_{xy}(f) = \frac{|\mathcal{P}_{xy}(f)|^2}{\mathcal{P}_{xx}(f) \cdot \mathcal{P}_{yy}(f)} \quad (3.10)$$

Onde:

- $C_{xy}(f)$: Coerência entre os sinais $x(t)$ e $y(t)$ na frequência f ;
- $\mathcal{P}_{xy}(f)$: Densidade espectral de potência cruzada entre os sinais $x(t)$ e $y(t)$;
- $\mathcal{P}_{xx}(f)$: Densidade espectral de potência do sinal $x(t)$;
- $\mathcal{P}_{yy}(f)$: Densidade espectral de potência do sinal $y(t)$.

A densidade espectral cruzada é definida como:

$$\mathcal{P}_{xy}(f) = \mathbb{E}[X(f) \cdot Y^*(f)] \quad (3.11)$$

Onde:

- $X(f)$ e $Y(f)$: Transformadas de Fourier dos sinais $x(t)$ e $y(t)$, respectivamente;
- $Y^*(f)$: Conjugado complexo da transformada de Fourier de $y(t)$;
- $\mathbb{E}[\cdot]$: Operador de valor esperado (média estatística sobre janelas ou ensaios).

No Matlab, a coerência entre dois sinais pode ser calculada utilizando a função `mscohere()`, que implementa a coerência quadrática média. Sua sintaxe básica é:

$$[Cxy, f] = \text{mscohere}(x, y, W, \text{olap}, \text{nfft}, fs);$$

Onde:

- x e y são os sinais entre os quais é calculada a coerência;
- W é a janela de segmentação;
- olap é o número de amostras de sobreposição entre janelas;

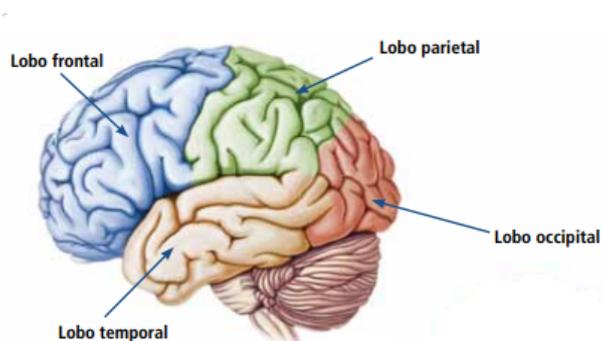
- $nfft$ é o número de pontos da FFT;
- fs é a frequência de amostragem dos sinais;
- C_{xy} é a coerência estimada em cada frequência;
- f vetor com os valores de frequência correspondentes.

O aumento ou diminuição da coerência pode ser observada em diferentes partes do sinal de EEG, dependendo do tipo de coerência. A coerência de fase, por exemplo, está relacionada à sincronização temporal dos sinais em diferentes regiões do cérebro e fica mais localizada nas bandas de frequências teta θ e alfa α . Já a coerência de amplitude, está relacionada à magnitude dos sinais em diferentes regiões do cérebro e pode ser observada nas bandas de frequências mais altas, como beta β e gama γ (NUNEZ; SRINIVASAN,2006).

Uma alta coerência é considerada como evidência da existência estrutural e funcional de conexões entre áreas corticais. Por outro lado, perda de coerência dos sinais de EEG tem sido identificada como uma característica comum em portadores da doença de Alzheimer, assim como nas demais demências. A coerência reduzida entre diferentes regiões do cérebro, medida pela coerência cruzada, é frequentemente observada em comparação a indivíduos saudáveis. Embora a perda de coerência seja um achado consistente em pacientes com doença de Alzheimer e outras demências, é importante destacar que a localização específica dessa perda pode variar. A DA afeta amplamente o cérebro, resultando em mudanças muito difusas em diferentes regiões cerebrais. Isso é um fator que dificulta significativamente a análise do problema, na esfera das doenças neurológicas (STAM; NOLTE; DAFFERTSHOFER,2007).

No Capítulo 5 deste trabalho, é apresentada uma RNA, treinada com sinais de EEG das regiões onde os reflexos provocados pela existência de DN sejam mais significativos.

A Figura 3.8 ilustra as regiões cerebrais. Sabe-se que os lobos Frontal (F), Temporal (T), Parietal (P) e Occipital (O) são mais susceptíveis a refletir variações decorrentes de alterações na coerência.

Figura 3.8: Regiões do cérebro.

Fonte: (CORRÊA, 2016).

3.5 Rede Neural Artificial

Uma rede neural artificial - RNA é inspirada no SNC humano, sumariamente abordado nas Seções 3.1 e 3.2. Tal qual no SNC humano, uma RNA é formada por unidades básicas, denominadas de neurônio artificial, nome herdado de seu modelo inspirador, o neurônio biológico humano. Assim, para melhor compreensão de uma RNA, é importante que se compreenda o comportamento de sua unidade básica, o neurônio artificial (GUPTA; JIN; HOMMA,2004).

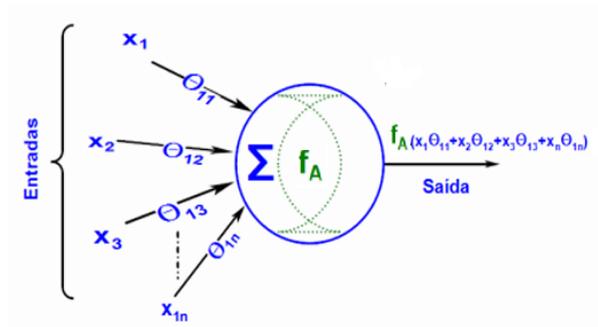
3.5.1 O neurônio artificial

Um neurônio artificial é um modelo matemático baseado no neurônio humano, apresentado na Seção 3.1 desta tese, e tem como objetivo simular o seu comportamento e funções. Um neurônio artificial foi apresentado em 1943 pelo neurofisiologista McCulloch e pelo matemático Pitts (MCCULLOCH; PITTS,1943) e pode ser resumido pela Figura 3.9. Nesse modelo, a saída do neurônio é ativada por uma função do somatório de suas entradas ponderadas.

Na Figura 3.10, verifica-se a semelhança entre o neurônio biológico humano e o neurônio artificial, apresentado na Figura 3.9.

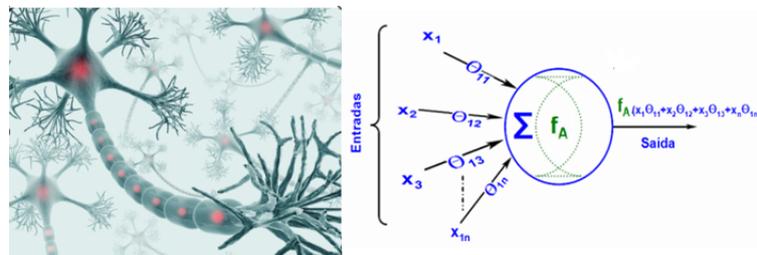
Os neurônios artificiais, quando organizados em camadas que se interconectam, formam uma RNA, que consiste numa das técnicas de inteligência artificial – IA.

Figura 3.9: Neurônio artificial.



Fonte: (Acervo do autor, 2025).

Figura 3.10: Semelhança entre os neurônios humano e artificial.



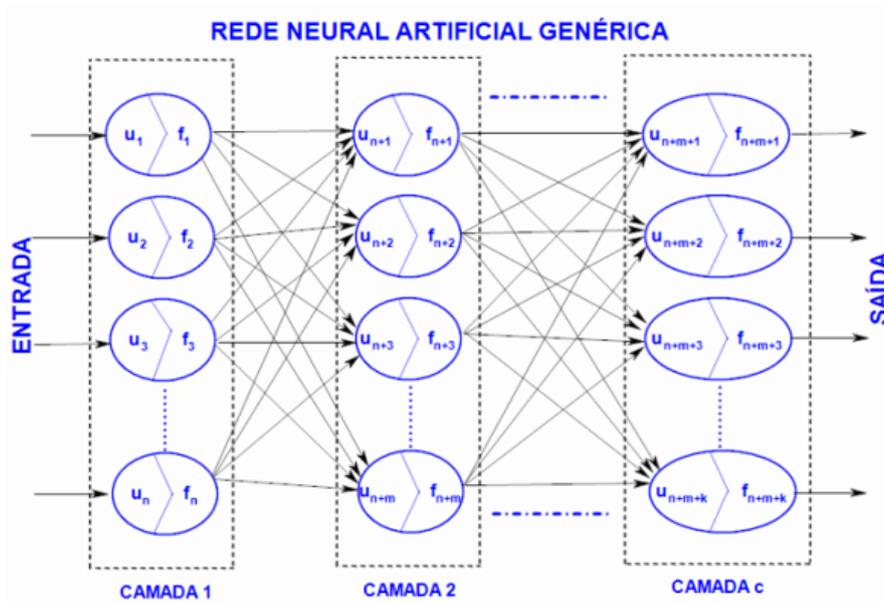
Fonte: (Acervo do autor, 2025).

3.5.2 Estrutura de uma RNA

Uma RNA pode ser definida como um sistema de processamento paralelo, estratificado em camadas, conforme a Figura 3.11.

Verifica-se que cada uma das camadas é composta por unidades independentes, os neurônios u_i , que operam sobre um conjunto de dados dispostos em sua entrada, seguindo um conjunto de regras e parâmetros pré-estabelecidos. Cada u_i , ao comando de uma função de ativação f_i produz um resultado em sua saída para entregar à camada subsequente. Esta, por sua vez, também seguindo um conjunto de regras pré-definido, opera sobre os dados recebidos da camada anterior, produzindo novo resultado para entregar à camada posterior. Isso se repete, até que a última camada (C) seja alcançada, momento em que os resultados ali produzidos, Y , são comparados com um valor de referência idealizado para o processo inteiro, T . O resultado dessa comparação é conhecido como erro do processo, E . Se esse erro é igual ou menor que

Figura 3.11: Rede Neural Artificial em blocos.



Fonte: (Acervo do autor, 2025).

um valor pré-estabelecido, o processo é encerrado; do contrário, um algoritmo de retroação é executado, com o objetivo de estabelecer novos parâmetros que venham a favorecer o alcance do valor idealizado, T . De forma simplificada, o erro E pode ser entendido como a diferença entre Y e T : $E = Y - T$.

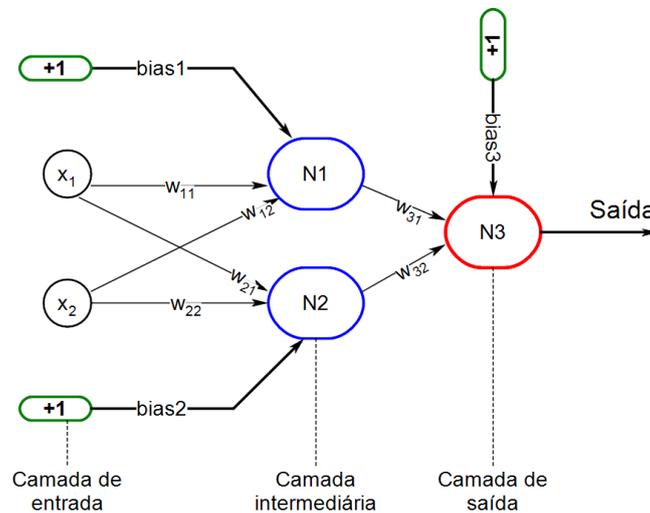
As funções de ativação f_i de cada neurônio u_i podem ou não ser iguais. A camada de entrada de uma rede neural não opera com função de ativação, ou seja, nesta camada, os valores de entrada de cada neurônio são replicados para respectiva saída. É o mesmo que dizer que, na prática, as operações dos neurônios só começam a partir da primeira camada intermediária. A escolha da função de ativação é uma tarefa de importância estratégica na implementação de uma RNA. Pode-se, por questão de conveniência e simplificação matemática, optar pelo uso da mesma função de ativação em todos os neurônios da rede, o que usualmente implica em melhor performance.

Conceitualmente, a modelagem de uma RNA é inspirada numa rede neural biológica, mais especificamente numa rede neural humana. Assim, a partir da camada intermediária, os círculos da 3.11 representam neurônios, onde ocorre proces-

samento e as setas representam fluxo de informação com respectivos pesos relativos. Na 1^a camada, esses círculos representam apenas nós, onde os dados de entrada são inseridos, e deles diretamente transferidos para os neurônios da camada intermediária, sem qualquer processamento prévio. Com isso, a primeira operação efetiva com os dados de entrada ocorre somente a partir da 1^a camada intermediária. A força de conexão entre as camadas da rede é definida pelos pesos de suas ligações, armazenados numa matriz de pesos sinápticos, Θ .

Como exemplo, considere-se a Figura 3.12, onde a rede tem a camada de entrada com dois nós, X_1 e X_2 , através dos quais os dados de entrada são inseridos na rede. W_{11} , W_{12} , W_{21} e W_{22} são os pesos que relacionam cada nó da camada de entrada com os neurônios da 1^a camada intermediária. Nesta descrição, o primeiro algarismo do índice de pesos W representa o neurônio da camada de destino, enquanto o segundo refere-se ao nó ou neurônio da camada de origem.

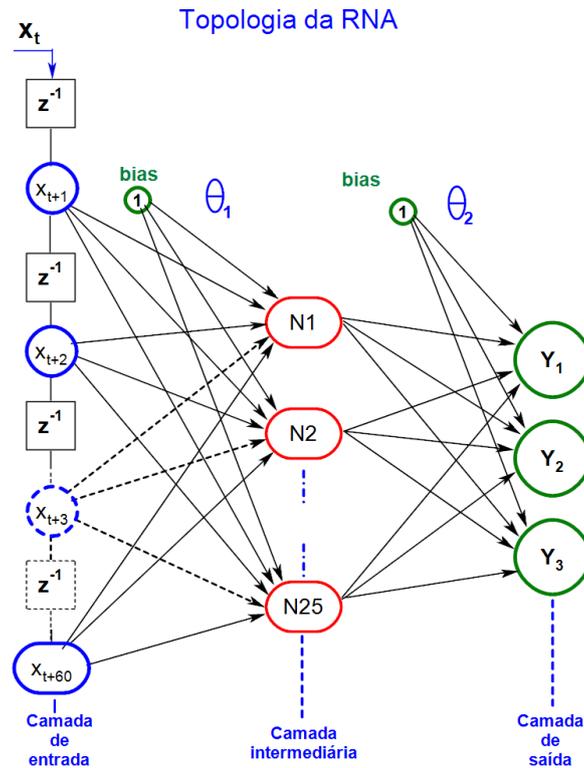
Figura 3.12: Rede Neural com 1 camada intermediária.



Fonte: (Acervo do autor, 2025).

A RNA implementada neste trabalho tem a topologia apresentada na Figura 3.13. São 60 nós na camada de entrada, camada intermediária única com 25 neurônios e camada de saída com 3 neurônios. Esta rede é detalhada no Capítulo 5, onde se descreve a sua implementação, treinamento e testes.

Figura 3.13: Rede Neural implementada.



Capacidade de aproximação de uma RNA

A capacidade que uma RNA possui para aproximar valores de um alvo predefinido é o que existe de mais importante para torná-la potencialmente útil em diversas aplicações, tais como identificação de sistemas e reconhecimento de padrões.

Uma RNA de propagação direta (*feedforward*) pode ser vista como uma regra para cálculo dos valores de saída nos vários neurônios de uma determinada camada, a partir dos valores de saída da camada imediatamente anterior. No aspecto matemático formal, pode-se expressar como o mapeamento de um espaço \mathbb{R}^n de entrada para um espaço \mathbb{R}^m de saída. Para a RNA, importa saber como realizar este mapeamento de \mathbb{R}^n para \mathbb{R}^m com a melhor aproximação possível e também quantas camadas e quantos neurônios em cada uma delas é suficiente para fazer tal aproximação. Estes aspectos de uma rede neural foram estudados por diversos pesquisadores, entre os quais podem ser destacados Gallant and White (GALLANT,1988),

Carroll e Dickinson (CARROLL; DICKINSON,1989), Cybenko (CYBENKO,1992) e Hecht-Nielsen (HECHT-NIELSEN,1992).

3.5.3 RNA estática, dinâmica e adaptativa

Quanto à dinâmica de processamento dos dados, uma RNA pode ser classificada em estática ou dinâmica.

RNA estática

Numa RNA estática não existe memória temporal, ou seja, o processamento do dado ocorre no instante em que o mesmo é recebido na sua camada de entrada, implicando que a sua saída depende exclusivamente do valor presente na entrada, a cada instante, sem considerar o contexto de entradas anteriores. Redes estáticas não possuem nó de retroalimentação, nem malhas de atraso. Neste tipo de rede, a saída é computada de forma direta, partindo da entrada para saída, através de conexões unicamente neste sentido(GUPTA; JIN; HOMMA,2004).

São exemplos de RNAs estáticas, as redes de propagação direta, como as redes neurais convolucionais, pois elas não possuem laços temporais ou dependências históricas. São ideais para aplicação em problemas que não tem dependência temporal ou necessidade de contexto passado, como reconhecimento de padrões estáticos, classificação de imagem. De uma forma geral, em aplicações cujo dado de entrada é independente dos demais, como reconhecimento de imagem e classificação estática de dados. Nestas redes, o treinamento é mais simples. Se utilizam de retropropagação padrão (algoritmo *backpropagation*). São mais rápidas para treinar e menos suscetíveis aos problemas de gradiente, comumente encontrados nas redes dinâmicas (GOODFELLOW; BENGIO; COURVILLE,2016).

RNA dinâmica

A RNA dinâmica leva em conta a dimensão temporal, ou seja, ela processa dados que variam ao longo do tempo, mantendo um histórico ou memória do que já foi

processado. Neste tipo de rede, a saída depende não apenas da entrada atual, mas também de entradas anteriores. Algum mecanismo de realimentação de referências é aplicado, de modo que a nova saída sofre influência seja da saída anterior, seja de parte da entrada anterior ou de ambas (GUPTA; JIN; HOMMA,2004;PICKLE; SHEARIN; FEY,2019).

Exemplos de RNAs dinâmicas são as redes neurais recorrentes e suas variantes. Essas redes têm conexões internas que permitem reter informações passadas, possibilitando que o estado da rede seja influenciado pelo histórico dos dados. Elas são usadas em tarefas como séries temporais, reconhecimento de fala, tradução automática e outras que exigem dependência temporal. Geralmente possuem conexões recorrentes ou realimentadas, onde a saída de um neurônio em uma camada pode ser usada como entrada para ele mesmo ou para neurônios em camadas anteriores. Esse tipo de conectividade permite que a rede retenha informações ao longo de uma sequência e, assim, ajuste seu comportamento com base no histórico. O treinamento dessas redes é mais complexo, pois envolve o uso de algoritmos que consideram a dependência temporal, como o BPTT (*Backpropagation Through Time*). Isso aumenta a complexidade computacional (PICKLE; SHEARIN; FEY,2019;HAYKIN,2001).

RNA adaptativa

Na RNA adaptativa, os parâmetros de operação se ajustam automaticamente, como resposta a uma demanda apresentada pelos dados que são por ela processados. Essa adaptação permite que a rede aprenda e melhore seu desempenho ao longo do tempo.

São aplicadas para reconhecimento de padrões, em sistemas de reconhecimento de fala, escrita e imagens, onde a adaptabilidade permite melhorar a precisão na identificação de padrões complexos. Também são encontradas em sistemas de controle que requerem ajustes em tempo real, como robótica e veículos autônomos, permitindo que o sistema responda a mudanças no ambiente de forma eficiente (PRINCIPE; EULIANO; LEFEBVRE,2000).

3.5.4 Critérios considerados para escolha da RNA

A escolha da RNA a ser aplicada no tratamento de um determinado problema raramente é uma atividade simples. Definir o tipo e topologia depende da aplicação e dos dados a serem processados. Numa escolha criteriosa, é importante considerar as técnicas de IA implicitamente aplicadas pelos algoritmos de aprendizagem. Isto permite que se opte por estratégias de implementação com o respaldo matemático oferecido pelo método, o que viabiliza o encontro de soluções mais estáveis, além de evitar a fatigante rota com destino incerto, mais conhecida como estratégia da tentativa e erro (Suzuki 2011) (LECUN; BENGIO; HINTON,2015; GOODFELLOW; BENGIO; COURVILLE,2016;SUZUKI,2011).

As RNAs são aplicadas para solução de problemas em diversas esferas do conhecimento humano, especialmente nos casos em que é possível identificar modelos de generalização. São exemplos de aplicações nas áreas de processamento de sinais biológicos (RODRIGUES et al.,2002;), classificação e análise de imagens (AGNIHOTRI; YADAV; KAUSHIK,2020;MAHMOOD; GHIMIRE,2013), sistemas auxiliares para agricultura (WANG,1994), entre outros.

Há problemas que não permitem a definição de um algoritmo único para sua solução. Eles são comumente descritos por um grande número de parâmetros ou variáveis que se relacionam de modo não regular. Por exemplo, diagnóstico médico baseado em múltiplos exames que requer a análise simultânea de sinais como EEG, exames de imagem (MRI), dados clínicos e laboratoriais; reconhecimento de padrões em imagens ou sinais, como detecção de tumores em radiografias ou identificação de emoções via EEG (JORDAN; MITCHELL,2015). As soluções para este tipo de problema são melhor processadas através de modelos com estrutura para execução de várias tarefas simultaneamente, de modo paralelo, tal qual ocorre com o cérebro humano. As RNAs, sendo uma das técnicas de IA, também são estruturas concebidas com este princípio. Sua característica mais relevante é a capacidade de aprender através de exemplo e a de generalizar a partir de treinamento. Dessa forma, são especialmente úteis, por serem capazes de aprender como resolver um novo pro-

blema, uma vez tenham sido treinadas com exemplos semelhantes. Diferentemente de outros métodos, não existe um algoritmo específico a ser seguido, mas sim uma estratégia que terminará por definir o melhor conjunto de parâmetros para alcançar determinado objetivo (LECUN; BENGIO; HINTON,2015).

3.5.5 Topologias de implementação de RNA

A topologia de uma RNA diz respeito às suas camadas, ao número de neurônios nelas distribuídos, assim como a função de ativação associada a cada um dos neurônios. Na primeira camada, a de entrada, os neurônios deverão ser em número suficiente para representar o sinal a ser processado pela rede, dentro de uma estratégia definida com esse propósito. Nas camadas intermediárias, esse número deverá ser o mínimo suficiente para atender aos critérios de convergência definidos pelo algoritmo usado na rede, enquanto na camada de saída deve atender ao critério de apresentação da resposta para ela definido.

Número de neurônios e camadas intermediárias de uma RNA

A definição do número ideal de neurônios nas camadas ocultas de uma RNA é uma tarefa complexa e ainda sem uma solução universalmente aplicável. Embora diversas estratégias empíricas e heurísticas tenham sido propostas ao longo dos anos, nenhuma abordagem isolada se mostrou eficaz para uma ampla variedade de problemas (GARSON,1998). A definição desse número afeta significativamente a performance de uma rede, uma vez que ele está diretamente relacionado à capacidade da RNA convergir ou não.

A escolha inadequada da quantidade de neurônios pode comprometer diretamente o processo de aprendizado da rede. Quando se utiliza um número excessivo de neurônios, o modelo pode sofrer com instabilidade no treinamento e dificuldade de convergência, fenômeno frequentemente associado ao chamado *overfitting*, onde o modelo se ajusta demais aos dados de treinamento e falha na generalização. Esse comportamento também pode gerar oscilações no gradiente, dificultando o ajuste

eficiente dos pesos sinápticos, caracterizando o que se pode chamar de divergência por excesso de capacidade.

Por outro lado, utilizar um número muito pequeno de neurônios resulta em um modelo com capacidade representacional limitada, dificultando que a rede entenda os padrões mais importantes presentes nos dados, assim levando a RNA à uma subconvergência ou aprendizado pobre. Em ambos os casos, a rede pode não convergir para uma solução adequada, mesmo após muitas iterações de treinamento, tornando a escolha do número de neurônios um fator crítico no desempenho final da RNA (GOODFELLOW; BENGIO; COURVILLE,2016).

Assim, métodos baseados em otimização bayesiana, ou mesmo técnicas adaptativas vêm sendo explorados para mitigar esse problema, de forma mais robusta (SHAHRIARI et al.,2016; GOODFELLOW; BENGIO; COURVILLE,2016).

O amadurecimento das técnicas trazem alguns avanços, na medida em que, depois de testes, permitem estimativas baseadas no tipo e tamanho dos dados processados pela rede (PANCHAL; PANCHAL,2014).

Até meados de 2007, as formas de definir esta questão eram bem diversas, entre as quais se destacavam as baseadas simplesmente em tentativa e erro, as baseadas em tentativa e erro seguidas de métodos heurísticos e também os algoritmos para ajuste dos parâmetros de uma RNA. No início de 2009, Stathakis apresentou uma técnica alternativa, baseada em algoritmos genéticos, que se propunha a definir a melhor topologia de uma RNA, através da introdução de uma nova função de condicionamento, com melhoria da performance e diminuição da complexidade da rede (STATHAKIS,2009). Antes disso, em 1993, o estudo de Villiers mostrou que redes com apenas uma ou duas camadas intermediárias podem ser muito eficientes na solução de problemas (VILLIERS; BARNARD,1993, o que foi confirmado em pesquisas posteriores, a exemplo da realizada por Huang, 10 anos depois (HUANG,2003)).

O teorema de Kolmogorov aplicado por Hecht-Nielsen

O teorema de Kolmogorov estabelece que qualquer função contínua definida em um espaço n -dimensional pode ser representada por somas e composições de funções contínuas de uma única variável. Com base nesse teorema, Hecht-Nielsen (1987) demonstrou que uma rede neural artificial de propagação direta (*feedforward*), com apenas uma camada intermediária, é capaz de aproximar qualquer função contínua, desde que contenha um número suficiente de neurônios nesta camada (HECHT-NIELSEN,1987). Em sua proposta, Hecht-Nielsen mostrou que qualquer função contínua pode ser representada por uma rede com uma única camada oculta, contendo pelo menos $2n + 1$ neurônios, onde n corresponde ao número de nós na sua camada de entrada. Contudo, a aplicação de Hecht-Nielsen destacou que a condição de possuir $2n + 1$ neurônios era válida para uma classe específica de função de ativação, um pouco mais complexa que as funções sigmoidais mais comumente utilizadas. Cinco anos mais tarde, em 1992, foi sugerido por Kůrková que o número de camadas intermediárias poderia aumentar para dois, para compensar a perda de eficiência, quando no uso dessas funções (KRKOVÁ,1992). Alguns anos depois, através dos trabalhos de Huang and Babri, entre 1997 e 2003, verificou-se que uma única camada intermediária poderia ser usada também com as funções sigmoidais mais tradicionais, desde que o número de neurônios fosse redefinido em função do número de amostras usadas para treinamento da rede. A adição de uma segunda camada intermediária objetiva reduzir significativamente o número de neurônios total dessas camadas.

Em 2003, ficou provado que numa RNA com duas camadas intermediárias e m neurônios na camada de saída, o número total de neurônios necessários nas camadas intermediárias, N_{HL} , pode ser expresso por

$$N_{HL} = 2\sqrt{(m + 2)n} \quad (3.12)$$

onde:

- N_{HL} é o número total de neurônios nas camadas intermediárias;
- m é o número de neurônios na camada de saída;
- n é o número de nós da camada de entrada.

E que o número de neurônios na primeira e segunda camadas intermediárias, respectivamente N_{HL1} e N_{HL2} , podem ser expressos por

$$N_{HL1} = \sqrt{(m+2)n} + 2\sqrt{\frac{n}{m+2}} \quad (3.13)$$

e

$$N_{HL2} = m\sqrt{\frac{n}{m+2}} \quad (3.14)$$

Assim, considerando a implementação de uma RNA com duas camadas intermediárias, sugere-se, no pior dos casos, que o número de neurônios dessas camadas seja definido conforme as equações 3.12, 3.13 e 3.14 (HUANG,2003).

Definição da melhor topologia para uma rede multicamada

A definição da topologia ideal para uma RNA multicamada continua sendo um desafio significativo no campo da inteligência artificial. Até o momento, não foi estabelecido um método preciso e universalmente aceito para determinar a configuração ótima dessas redes. Na prática, diversas abordagens têm sido empregadas para viabilizar a implementação eficaz de RNAs multicamadas. Entre as principais técnicas utilizadas destacam-se:

- **Método da tentativa e erro:** É a forma mais primitiva e, por consequência, muito vulnerável em resultado. Consiste na experimentação empírica de diferentes arquiteturas de rede, ajustando parâmetros como o número de camadas ocultas e neurônios por camada, até alcançar um desempenho satisfatório. Embora seja simples, este método pode ser demorado e não garante a obtenção da topologia ótima.

- **Método da procura heurística:** Baseado em heurísticas previamente definidas na literatura, as quais tomam como referência experimentos já realizados. O objetivo de tais heurísticas é sempre definir o número de neurônios das camadas intermediárias em função do número de neurônios nas camadas de entrada e saída ou a seleção de funções de ativação adequadas. Através desse método, os resultados obtidos podem se mostrar em topologia única (RIPLEY,1994), ou pela apresentação de diversas possíveis topologias, que neste caso, precisam ser investigadas para permitir a escolha daquela que melhor se adequa ao propósito desejado (KANELLOPOULOS; WILKINSON,1997). Na prática, tais heurísticas são frequentemente usadas como ponto de partida para aplicação do método tentativa e erro, o que representa considerável ganho na qualidade dos resultados obtidos por tal método.
- **Método da procura exaustiva:** Envolve a avaliação sistemática de todas as combinações possíveis de topologias dentro de um conjunto predefinido de parâmetros. Embora possa identificar a configuração ideal, este método é computacionalmente intensivo e, muitas vezes, impraticável. A busca por todas as possíveis topologias para implementação é uma questão inviável, não por ser uma grande quantidade, mas pelo longo tempo envolvido na avaliação de cada uma. Este método é ainda afetado por uma característica presente em redes neurais: resultados diferentes são obtidos, caso condições de inicialização diferentes sejam usadas, mesmo que os demais parâmetros da rede sejam mantidos exatamente iguais. Essa característica é conhecida como ruído de avaliação da rede. O número de amostras de referência usadas no treinamento de uma rede ajuda a diminuir o impacto da dificuldade imposta por esse ruído (YAO,1993).
- **Método dos algoritmos adaptativos:** Este método propõe a definição de uma rede neural a partir da alteração de sinapses (pesos), conforme os resultados obtidos a cada operação da rede. Alguns algoritmos dessa classe são mais frequentemente aplicados, a exemplo OBD - Optimal Brain Damage (CUN; DENKER; SOLLA,1989) e OBS - Optimal Brain Surgeon (HASSIBI;

STORK,1992). Um estudo comparativo desses algoritmos foi realizado por Kavzoglu e Mather, sendo constatado que os melhores resultados são obtidos com o algoritmo OBS (KAVZOGLU; MATHER,1999).

A escolha do método mais adequado depende de fatores como a complexidade do problema, recursos computacionais disponíveis e a necessidade de precisão na modelagem.

Estratégias de implementação de RNA

Uma das mais importantes características de uma RNA é a sua habilidade para se adaptar às mudanças de características do sistema para qual foi concebida. Nesse sentido, é de se esperar que uma rede se mantenha útil e eficiente, mesmo que o sistema para qual foi modelada apresente instabilidades.

É muito importante que a etapa de implementação de uma RNA seja orientada por um princípio, denominado aqui por Princípio da Simplicidade (SHARMA; SHARMA; ATHAIYA,2017). Ele pode e deve ser aplicado a todas as fases de implementação da RNA, começando pela escolha da topologia e da função de ativação para cada neurônio (KARLIK; OLGAC,2011), até a definição da estratégia de treinamento. Quanto mais simples for a rede, maior a sua capacidade de convergir, o que agiliza todos os seus processos, começando pelo treinamento e, por consequência, sua performance geral.

Na prática, uma RNA pode ser aplicada como uma plataforma de software ou hardware. No primeiro caso, o acesso à RNA pode ocorrer por interface de arquivos ou ainda de periféricos, como porta serial, paralela, ethernet, bluetooth, entre outras; no segundo, quando a rede deve estar embarcada em uma placa eletrônica, o seu acesso pode ser feito em conformidade com os recursos de interface implementados na placa, podendo ser conexão proprietária direta com o barramento do sinal de entrada, assim como também através de interfaces padronizadas, como as listadas para o primeiro caso (NIELSEN,2015).

Qualquer que seja a plataforma escolhida, uma RNA deve ser dotada de meca-

nismo capaz de viabilizar o seu processo de aprendizagem com o menor erro possível. Estes mecanismos são implementados através de algoritmos de aprendizagem, sendo o de retropropagação (*Backpropagation*) um dos mais aplicados em redes artificiais multicamadas. Ele apresentado na seção a seguir (NIELSEN,2015) (GOODFELLOW; BENGIO; COURVILLE,2016).

O algoritmo de retropropagação (*Backpropagation*)

O *Backpropagation* (BP) é um algoritmo de busca do valor mínimo da função de custo. Ele emprega a técnica de gradiente descendente. Esta técnica estabelece que uma vez alcançado o valor mínimo dessa função, os parâmetros que a levam a este valor mínimo é uma solução para o processo de aprendizagem.

Embora existam outros que podem ser aplicados, conforme o interesse, o método mais usado para cálculo do erro é o quadrático médio, expresso por

$$\text{ERRO} = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2, \quad (3.15)$$

onde:

- ERRO é o erro médio quadrático;
- n é o número total de amostras da saída;
- y_i é a saída real no instante i ;
- t_i é a saída ideal no instante i ;

A saída t_i em 3.15 está associada a uma hipótese de valores idealizados. O fluxo do algoritmo BP é iniciado na camada de saída, retroagindo até a camada inicial de pesos, pelo cálculo do gradiente em cada neurônio. As derivadas parciais, gradientes, de uma camada são reutilizados no cálculo do gradiente da camada anterior, em cadeia. Ocorre, dessa forma, o retrocesso das informações de erro e, por consequência, o cálculo do gradiente em cada camada (KANDEL; SCHWARTZ; JESSELL,2013). O algoritmo BP se mostrou eficiente para variadas aplicações, se

tornando um dos estimuladores à disseminação da técnica de RNA. É inquestionável o fato de que o BP já tenha comprovado sua eficiência como método para treinamento de redes multicamadas. Contudo, mesmo assim não está livre de problemas. Ele é afetado por alguns aspectos inerentes ao processamento de uma rede multicamada típica, tais como parâmetros de inicialização, taxa de aprendizado, tamanho da rede e dados para treinamento. A escolha acertada desses parâmetros resulta num treinamento eficiente; por outro lado, caso a escolha seja inadequada, a operação de treinamento se torna lenta, podendo inclusive ser inviabilizada (GUPTA; JIN; HOMMA,2004). A eficiência do algoritmo BP tem relação direta com o tamanho da rede, ou seja, com sua topologia. Assim, emerge mais uma vez o famoso problema das redes multicamadas, a definição do melhor número de camadas intermediárias e dos respectivos neurônios. Como já tratado na Seção 3.5.5, esta questão ainda não dispõe de método que apresente uma resposta pronta. O método da tentativa e erro ainda tem sido muito usado, ainda que os esforços já aplicados na busca da solução tenham trazido alternativas para situações bem específicas (STATHAKIS,2009). Ressalte-se sempre que uma RNA é tão melhor quanto menor ela for, desde que o suficiente para solucionar o problema para qual tenha sido implementada.

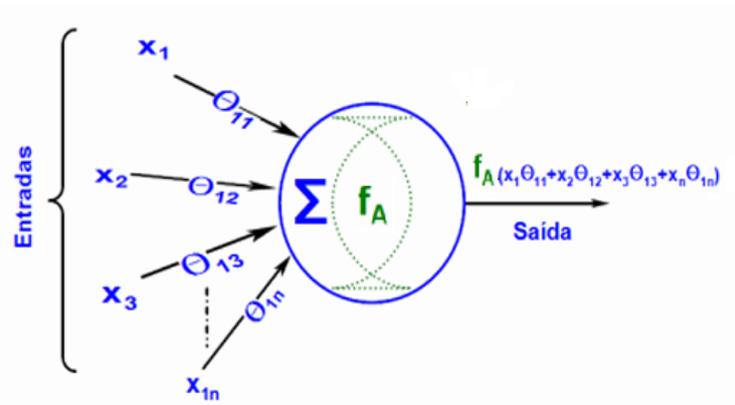
Funções de ativação de uma RNA

Numa RNA, uma função de ativação $f_A(x)$ cumpre o papel de um operador matemático entre o sinal inserido na entrada de um neurônio, devidamente ponderado conforme suas conexões, e a saída desse mesmo neurônio, atuando verdadeiramente como um controle da saída, como mostra a 3.14.

Uma função de ativação tem um propósito matemático, que é o de introduzir uma não-linearidade ao processo, o que irá permitir o aprendizado da rede não limitada à linearidade, pois é baseado nessa relação não-linear. Esse aspecto é muito importante pela influência que tem sobre o algoritmo executado na busca do custo mínimo da rede.

Na prática, o objetivo da função de ativação $f_A(x)$ é transformar o valor existente

Figura 3.14: Neurônio artificial sob efeito de uma função de ativação.



Fonte: (Acervo do autor, 2025).

na entrada de um neurônio para entregá-lo à camada subsequente. A performance de uma RNA é dependente de sua topologia, como antecipado na Seção 3.5.5, sendo relevante o papel da $f_A(x)$ escolhida para seus neurônios (KARLIK; OLGAC,2011; (SHARMA; SHARMA; ATHAIYA,2017)). Sendo assim, esta escolha, como qualquer outra que afete o processamento da rede, deve estar em sintonia com o princípio da simplicidade. Uma característica importante que uma fA precisa possuir é a da eficiência computacional, uma vez que ela é executada uma enorme quantidade de vezes sobre todos os neurônios da rede.

Entre as razões pela preferência das funções matemáticas mais aplicadas para ativação de neurônios, existem características comuns que merecem destaque: o seu intervalo limitado, a facilidade para cálculo de sua derivada e por apresentarem propriedades matemáticas em sintonia com as da Teoria da Aproximação ((KARLIK; OLGAC,2011); (TREFETHEN,2019)).

Além das funções sigmóide e tangente hiperbólica, que são as sigmoidais mais usadas, outras duas são aqui lembradas, por serem muito aplicadas no desenvolvimento de RNAs MLP.

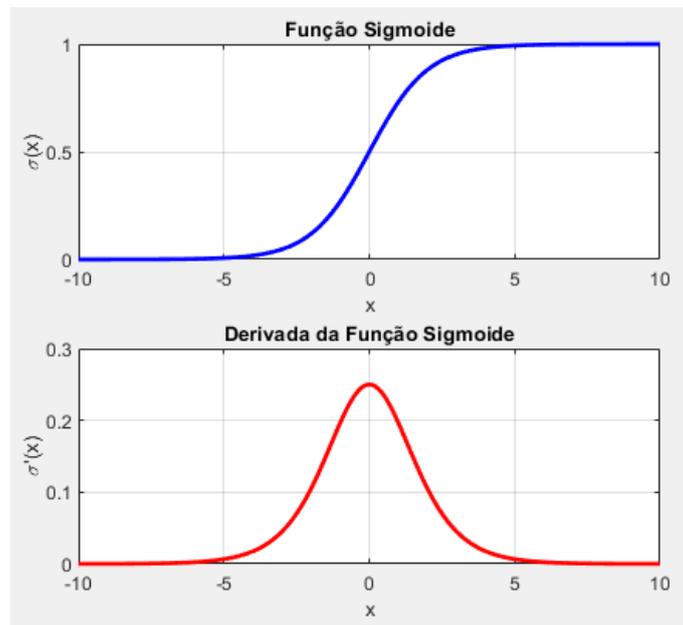
1. A função Sigmóide:

A função sigmoide é expressa por

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.16)$$

A Figura 3.15 apresenta o gráfico da função sigmoide e de sua derivada.

Figura 3.15: Gráficos da função Sigmóide e de sua derivada.



Fonte: (Acervo do autor, 2025).

Sobre a função Sigmoide, verifica-se:

Vantagens: Derivada suave, valores no intervalo 0 a 1.

Desvantagens: Descentralizada em relação à origem; por variar entre 0 e 1, pode causar lentidão no aprendizado, já que todos os neurônios têm saída positiva, resultando em gradientes não balanceados (LECUN et al.,1998; NWANKPA et al.,2018).

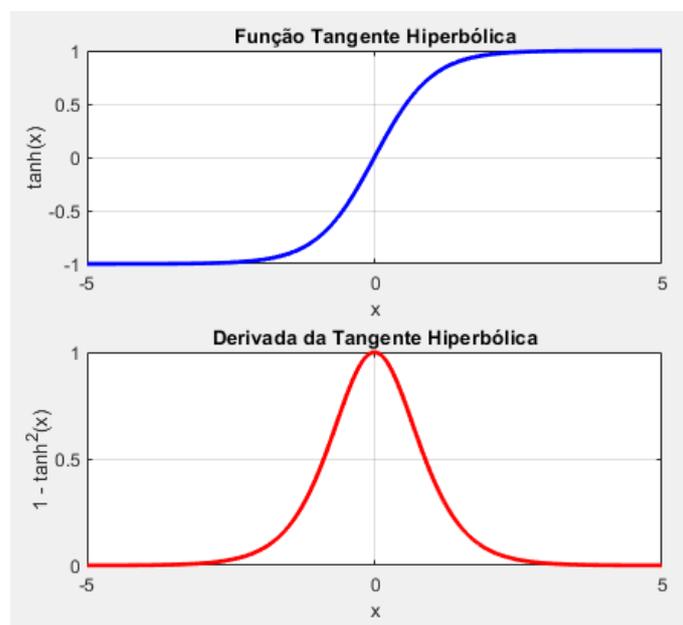
2. A função Tangente Hiperbólica

A função Tangente Hiperbólica é expressa por

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.17)$$

A Figura 3.16 apresenta o gráfico da função Tangente hiperbólica e de sua derivada.

Figura 3.16: Gráficos da função Tangente hiperbólica e de sua derivada.



Fonte: (Acervo do autor, 2025).

Sobre a função Tangente Hiperbólica, verifica-se que a saturação de sua derivada ocorre num patamar superior ao da sigmoide, o que implica que é um pouco mais rápida em convergir:

Vantagens: Saída centrada em zero, valores no intervalo -1 e 1; Boa sensibilidade a variações próximas da origem: Quando x está entre -1 e 1, a função é mais sensível às mudanças, o que pode ajudar no aprendizado fino.

Desvantagens: Saturação em extremos: Para valores muito positivos ou muito negativos de x , os gradientes se aproximam de zero; por envolver exponenciais, pode ter maior custo em hardware embarcado de baixa performance. (GLOROT; BEN-

GIO,2010)

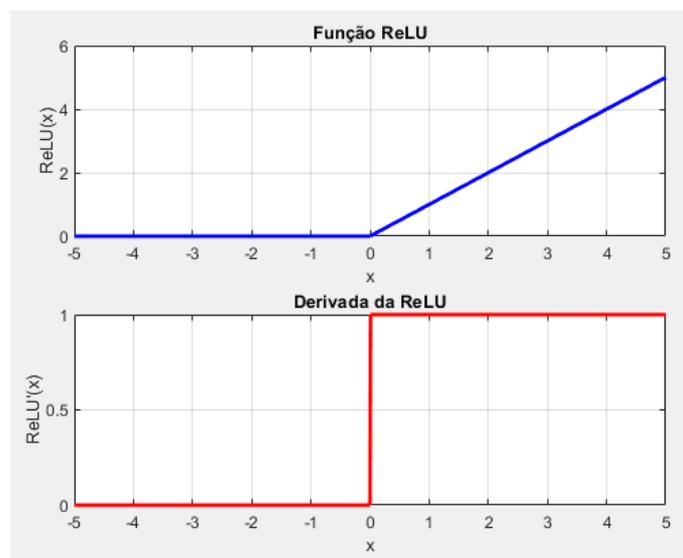
3. A função ReLU

A função ReLU é expressa por

$$\text{ReLu}(x) = \begin{cases} 0, & \text{se } x \leq 0 \\ x, & \text{se } x > 0 \end{cases} \quad (3.18)$$

A Figura 3.17 apresenta o gráfico da função ReLU e de sua derivada.

Figura 3.17: Gráficos da função ReLU e de sua derivada.



Fonte: (Acervo do autor, 2025).

Essa função, apesar de simples e linear por partes, introduz não linearidade numa rede neural por causa da descontinuidade de sua derivada em $x = 0$ e da quebra da linearidade em torno do zero. O fato dela possuir comportamento distinto em dois domínios ($0, \text{ se } x \leq 0; x \text{ se } x > 0$), impede que uma RNA aplicando a ReLU seja equivalente a uma simples combinação linear de pesos, quando o número de camadas que a apliquem seja maior ou igual a dois(2) (NAIR; HINTON,2010). A composição de várias camadas com ReLU permite que a RNA aproxime funções não lineares.

Mesmo que cada unidade seja linear para $x > 0$, a combinação de várias ReLUs em diferentes regiões do espaço de entrada cria fronteiras não lineares complexas.

Resumindo, a ReLU é tecnicamente uma função não linear por partes, o que é suficiente para que a RNA possa aprender relações não lineares, desde que existam múltiplas camadas.

Sobre a função ReLU, verifica-se:

Vantagens: Computacionalmente eficiente: Simples de calcular, pois requer apenas uma comparação; evita saturação: Não possui limite superior, o que ajuda a evitar o problema do desvanecimento do gradiente nas camadas superiores.

Desvantagens: Morte de neurônios (*dying* ReLU): Neurônios podem parar de aprender se a entrada for sempre negativa (gradiente nulo); não centrada na origem (AGARAP,2018; NAIR; HINTON,2010; GLOROT; BORDES; BENGIO,2011).

4. A função Swish

A função Swish é expressa por

$$\text{Swish}(x) = x \cdot \frac{1}{1 + e^{-\beta x}} \quad (3.19)$$

Onde β é um parâmetro que pode ser fixo ou aprendido durante o treinamento (sendo comum usar $\beta = 1$).

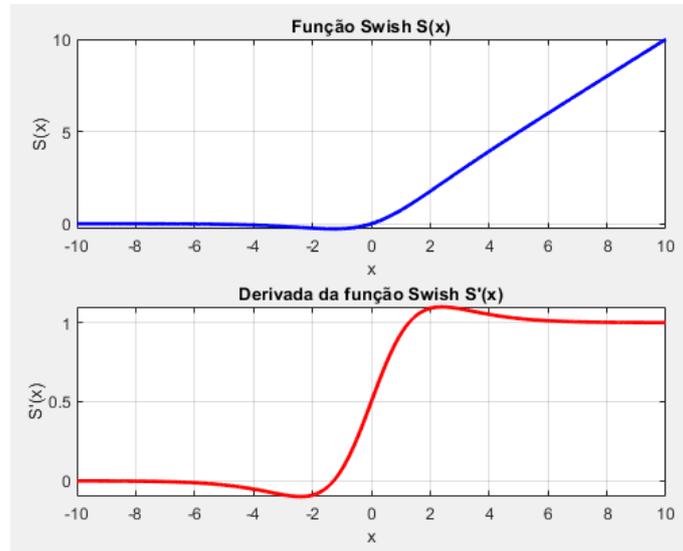
A Figura 3.18 apresenta a função Swish e a sua derivada.

Sobre a função Swish, verifica-se:

Vantagens: diferenciável em todo o domínio, favorecendo otimização mais estável; favorece a modelagem de padrões mais complexos, graças à sua forma curva, inclusive com valores negativos moderados.

Desvantagens: Instabilidade em algumas arquiteturas: Em casos específicos, pode introduzir dificuldades na convergência. (RAMACHANDRAN; ZOPH; LE,2017; ELFWING; UCHIBE; DOYA,2018)

Figura 3.18: Gráficos da função Swish e de sua derivada.



Fonte: (Acervo do autor, 2025).

Pressupõe-se que uma RNA MLP permite o uso de várias combinações de funções de ativação, cada qual conduzindo a uma performance. Contudo, a prática revela que, em alguns casos, a escolha de uma única função de ativação para todos os neurônios da rede pode representar a melhor alternativa.

*”Toda a nossa ciência, comparada
à realidade, é primitiva e infantil
— e ainda assim é a coisa mais
preciosa que temos.”*

Albert Einstein.

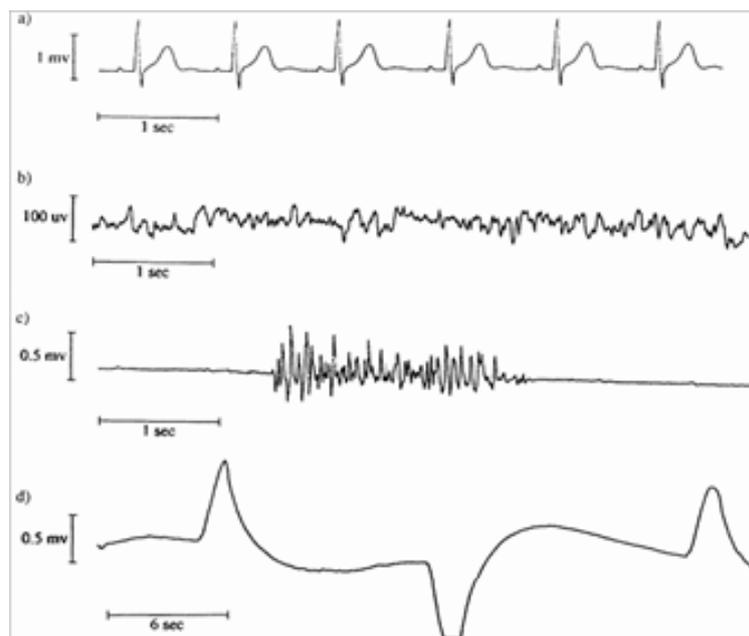
Capítulo 4

Aquisição e Processamento de Sinais Bioelétricos

Disponibilizar recurso que permita a uma equipe médica diagnosticar com segurança é muito importante para o sucesso no tratamento de doenças. Contudo, obter uma medição precisa, através da qual se possa avaliar o estado de determinada parte do corpo, órgão ou sistema não é uma tarefa simples. Uma causa disso é que os sinais elétricos envolvidos nessas medições têm amplitudes baixas, na ordem de mili ou microvolts (mV ou μV), o que os torna vulneráveis a contaminação por outros sinais elétricos presentes no ambiente e até mesmo aqueles decorrentes do processo de aquisição. Com relação aos sinais biológicos, esses sinais contaminantes são denominados artefatos. A Figura 4.1 apresenta um exemplo dos sinais emitidos pelo cérebro, coração, olhos e músculos, destacando a ordem de grandeza de suas amplitudes.

Em ‘a’, um eletrocardiograma (ECG), com amplitudes de até $1 mV$; em ‘b’, um eletroencefalograma (EEG), com amplitudes de até $100 \mu V$; em ‘c’, um eletrooculograma (EOG), com amplitudes de até $0,5 mV$; em ‘d’, um eletromiograma (EMG), com amplitudes de até $0,5 mV$. Outras técnicas para registros de biosinais elétricos também são aplicadas, a exemplo da magneto-encefalografia (MEG), mas as primeiras ainda são as mais aplicadas (FOX et al.,2000).

Figura 4.1: Sinais biológicos: a) no coração b) no cérebro c) nos olhos d) nos músculos.



Fonte: (WEEBLY,2024).

Por envolver esses detalhes técnicos, a aquisição de sinais bioelétricos do corpo humano requer uma série de cuidados, sem os quais ela não é confiável. De um modo geral, ela envolve: o uso de eletrodos especiais, a preparação da superfície de contato com gel eletrolítico para fixação destes eletrodos em posições específicas do corpo, circuitos eletrônicos capazes de eliminar os sinais indesejáveis, entre outros.

4.1 Sinais elétricos do cérebro

Cada músculo ou órgão possui um potencial de ação que lhe é característico. Com relação aos sinais originados no cérebro, faz-se aqui uma abordagem sumária sobre os seus aspectos relevantes, diretamente relacionados ao processamento para identificação de padrões.

Os sinais biológicos originados no cérebro possuem baixa amplitude, na ordem de microvolts (μV), sobretudo quando capturados de maneira não-invasiva, tal qual ocorre com o eletroencefalograma, EEG (SILVA,2013). Sendo assim, são facilmente

confundidos com outros sinais de origens diversas, os artefatos, que acabam contaminando o sinal de EEG original, no momento de sua aquisição. As principais fontes de artefatos são a atividade muscular, o piscar de olhos durante a captura do EEG e os ruídos da rede elétrica. Quando o sinal de EEG é contaminado, a tarefa de seu reconhecimento e classificação se torna ainda mais complexa, uma vez que os artefatos diminuem consideravelmente a utilidade do sinal biológico capturado.

No cérebro, uma excitação elétrica das células produz uma ação potencial que se estende até os dendritos e axônios. O registro da atividade dos neurônios e suas interações no córtico cerebral correspondem ao eletroencefalograma (EEG). (NUNEZ; SRINIVASAN,2006). Esta atividade é obtida a partir de eletrodos posicionados sobre o couro cabeludo, conforme orientação técnica devidamente padronizada. Essa é a modalidade de captura não-invasiva, preferida e tradicionalmente utilizada na área médica. Entretanto, em situações específicas, ocorre a necessidade de diminuir a resistência de contato entre os eletrodos e os respectivos pontos de conexão, com o propósito de capturar sinais mais expressivos, com maior amplitude. Nesses casos, os eletrodos, normalmente de platina ou aço-inoxidável, são conectados de forma invasiva, diretamente no cérebro (MA et al.,2014).

Problemas na aquisição de sinais de EEG são ocasionados por fontes de artefatos fisiológicos e não fisiológicos. As fontes fisiológicas podem ser originadas por movimento, contração muscular, movimento dos olhos, piscadas, e ainda sinais das batidas do coração. Os artefatos não fisiológicos são, em sua maioria, interferências elétricas originadas de fontes comuns como linhas de potência da rede elétrica, rádio frequência (RF) e interferências magneticamente induzidas. O aterramento da rede elétrica, assim como o uso de técnicas de medição adequadas, pode atenuar os efeitos de tais fontes de ruídos e interferências (PEREIRA; RICARDO,2019).

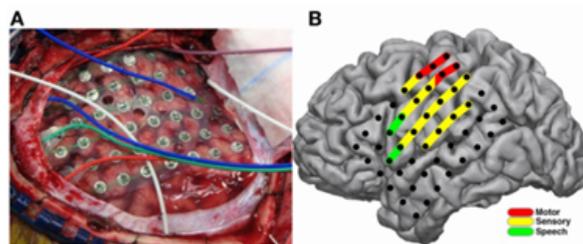
4.1.1 Morfologia do EEG

Os sinais de EEG são caracterizados por baixa amplitude e alta complexidade de análise. Um ser humano em condições normais possui, na média, amplitude entre

20 e 100 μV , com frequência de 0,1 a 30 Hz, encontradas nos estados mais típicos. Em situações extraordinárias, a frequência pode alcançar valores próximos de 100 Hz.

A aquisição do sinal de EEG pode ocorrer por método invasivo ou não-invasivo. No primeiro caso, os elementos coletores entram em contato direto com a superfície craniana. Por este método, ocorre a necessidade de penetrar o crânio. Como resultado, verifica-se um sinal EEG de maior amplitude, o que facilita o seu processamento. Por outro lado, a complexidade do procedimento é significativa, além dos riscos de infecção e traumas, decorrentes da abertura do crânio. Na Figura 4.2 é apresentado um dos tipos de interface com eletrodos usada em métodos invasivos (SHAH; MITTAL,2014).

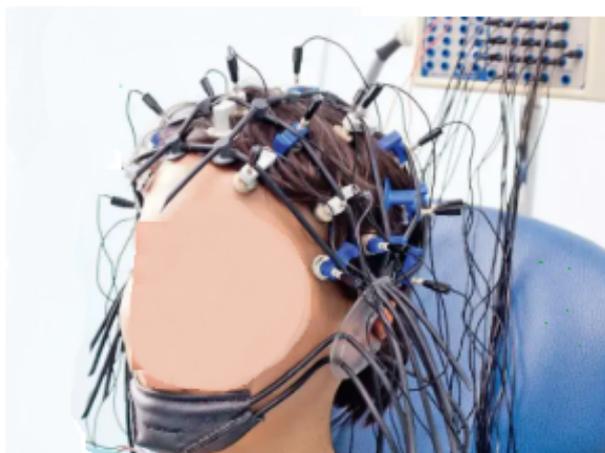
Figura 4.2: EEG: Interface de eletrodos para método invasivo.



Fonte: (FOUNDATION,2020).

No método não-invasivo, eletrodos não-descartáveis, geralmente com placa de ouro ou prata, são fixados na superfície couro cabeludo, de forma a obter baixa impedância de contato. O eletrodo permite uso de gel eletrolítico ou pasta condutora para melhorar a interface pele-eletrodo. De um modo geral, oferece risco muito baixo de infecção ou mesmo outra complicação decorrente da realização do procedimento, razão pela qual ele é o mais usado. O método não-invasivo requer o posicionamento dos eletrodos obedecendo alguns critérios para viabilizar a aquisição de sinais de melhor qualidade, ou seja, maior amplitude (MANTRI et al.,2015).

Figura 4.3: EEG: Interface de eletrodos para método não-invasivo.



Fonte: (Acervo do autor,2025).

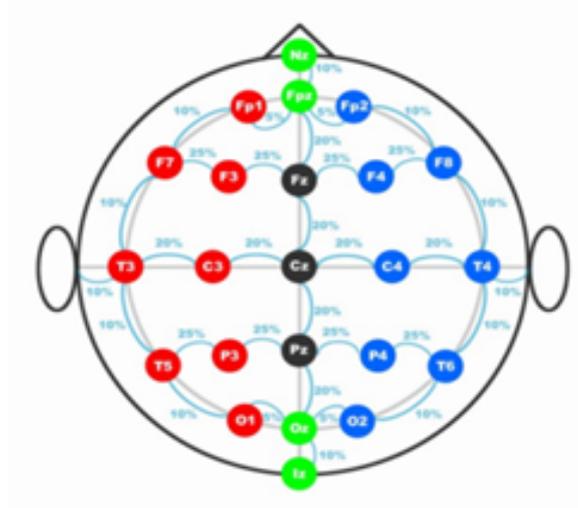
4.1.2 EEG não-invasivo: Padrões para posicionamento dos eletrodos

Existem três padrões que estabelecem o posicionamento dos eletrodos para a aquisição do sinal de EEG pelo método não-invasivo: O Sistema 10-20, o Sistema 10-10 e o Sistema 10-5.

O primeiro padrão internacionalmente aceito é o Sistema 10-20, apresentado na Figura 25. Ele define a localização dos eletrodos na superfície da cabeça com relação a pontos tomados como referência, o nasion localizado no topo do nariz, entre as sobrancelhas e o inion que fica na base do crânio, atrás da cabeça. Seu principal objetivo é ser um padrão amplamente aplicável, que estabelece um método de fácil reprodução, usando um número relativamente pequeno de eletrodos. Este sistema utiliza 21 pontos, que são marcados dividindo o crânio em proporções de 10% ou 20% do comprimento das distâncias entre os pontos de referência, nasion e inion no plano medial e os pontos pré-auriculares no plano perpendicular ao crânio (SILVA et al.,2003).

A nomenclatura dos pontos é estabelecida de acordo com a região em que estão localizados: F (frontal), Fp (frontal polar), T (temporal), C (central), P (parietal) e O (occipital). Os pontos localizados sobre a linha média são indexados pela letra z,

Figura 4.4: EEG: Sistema 10-20 para posicionamento de eletrodos.



Fonte: (UMICH,2020).

de zero; os pontos localizados do lado esquerdo da linha média, por índices ímpares; e à direita, por índices pares.

A distância entre os pontos nasion e inion é tomada como medida de referência, MRef. A partir deles, sobre a linha mediana do crânio, são marcados os pontos Fpz e Oz com distância de 10% de MRef; e os pontos Fz, Cz e Pz, com 20% de MRef.

Com a evolução da tecnologia para EEG e o advento de equipamentos multicanais, houve a necessidade por sistemas com maior quantidade de eletrodos, o que levou à definição do Sistema 10-10, apresentado na Figura 4.5 . Consiste numa extensão lógica do Sistema 10-20, com 64 pontos para conexão de eletrodos. Nele, o distanciamento entre os pontos é sempre de 10% de MRef ao longo do contorno medial lateral (CHATRIAN; LETTICH; NELSON,1985).

Um sistema com ainda mais contornos, implicando maior densidade de pontos para eletrodos é visto na Figura 4.6 (Chatrian, Lettich, e Nelson 1985).

Um estudo comparativo dos três sistemas (10-20, 10-10 e 10-5) pode ser visto em (JURCAK; TSUZUKI; DAN,2007).

4.1.3 Interpretação de um sinal de EEG

A interpretação de um sinal de EEG deve considerar diversos fatores inerentes ao cérebro, sendo um deles o fato de seus neurônios se organizarem de acordo com a frequência em que vibram, isto é, neurônios que vibram numa mesma faixa de frequência tendem a se organizar, formando grupos.

Durante a execução de um EEG, são emitidos sinais de estímulo luminoso em determinadas faixas de frequência, que são percebidos pelos neurônios que vibram nas mesmas faixas de frequência dos estímulos emitidos. Estes, por sua vez, emitem um sinal elétrico em resposta a esses estímulos, que é captado pelos eletrodos adequadamente posicionados para esse fim. Este sinal de resposta é formado por ondas que, em determinadas situações, ordinariamente se encontram presentes, sendo denominadas como:

- **Onda Gama γ** : Na faixa de frequência entre 30 e 50 Hz (ordinariamente), podendo alcançar até 100 Hz. Está associada a processos de estímulos táteis, visuais e auditivos, assim como a instantes onde o cérebro tem maior rendimento no aspecto de memorização de curto prazo.
- **Onda Beta β** : Na faixa de frequência entre 13 e 30 Hz, nas situações de vigília, alerta e concentração. Caracteriza-se por possuir baixa amplitude, estando associada a momentos de atividade cerebral intensa.
- **Onda Alfa α** : Na faixa de frequência entre 7 e 13 Hz, em situação de vigília, acompanhada de relaxamento. Possui maior amplitude que a onda Beta β e está associada a estados de restauração (descanso) pós atividade cerebral intensa.
- **Onda Teta θ** : Na faixa de frequência entre 4 e 7 Hz, em situação de atividade cerebral reduzida, quase dormindo.
- **Onda Delta δ** : Na faixa de frequência entre 0.1 e 4 Hz, em situação de sono profundo (KEIL et al.,2001).

Essas ondas cerebrais são consequência da interação entre vários dos neurônios localizados no cérebro, que mediante estímulos diversos, também respondem de forma diversa (Başar et al. 2001; Nunez e Srinivasan 2006). Apesar dessa diversidade, sabe-se que, conforme a atividade desenvolvida pelo indivíduo, tais ondas se encontram mais ou menos presentes, configurando atividade cerebral específica. Assim, também se verifica que, conforme a atividade desenvolvida pelo indivíduo, os padrões de onda cerebral beta β , alfa α , teta θ e delta δ estão presentes, em maior ou menor intensidade. Há atividade em que o indivíduo se encontra mais focado, com muita atenção; noutras, em que há um estado de relaxamento, dispersão, meditação; outras ainda, sob estresse mental e assim por diante. Resumindo, as atividades podem ser percebidas através das ondas cerebrais (BAŞAR et al.,2001;NUNEZ; SRINIVASAN,2006).

A possibilidade de identificar o nível de atividade em um indivíduo pela correlação com a sua atividade cerebral através de um sinal de EEG representa uma conquista importante, uma vez que se constitui numa alternativa para viabilizar estudos em áreas, como as relacionadas ao diagnóstico e tratamento de doenças do sistema neurológico.

4.2 Técnicas para processamento de sinais bioelétricos

Um sinal bioelétrico tem características peculiares, entre as quais são comuns a baixa amplitude, a baixa frequência e a não-periodicidade. O seu processamento requer aplicação de procedimentos especiais, no sentido de garantir a sua autenticidade. Eles são executados no decorrer de todo processo, desde a aquisição do sinal até a conclusão de seu processamento. Nesse aspecto, referindo-se especificamente aos sinais de EEG, abordados na Seção 4.1, o parâmetro frequência é de importância relevante.

De um modo geral, a análise de um sinal bioelétrico envolve um processo de amostragem que é executada em conformidade com o Teorema de Nyquist, sendo comum sua apresentação em Amplitude *versus* pontos da amostra. Além disso,

a aplicação de estratégias de aquisição e técnicas de processamento de sinal são imprescindíveis para viabilizar a análise desejada.

Na fase de aquisição, um dos recursos mais utilizados é o amplificador de instrumentação. Após a aquisição, o sinal bioelétrico precisa ser condicionado a padrões que permitam o seu processamento, o que implica num pré-processamento, que é realizado através de técnicas de processamento digital de sinais (PDS), como as apresentadas na Seção 4.2.3.

As técnicas de PSD desempenham um papel essencial em praticamente todas as etapas da análise de sinais bioelétricos. Considerando um sinal de EEG, após sua aquisição, torna-se necessário aplicar procedimentos de pré-processamento que garantam a integridade da informação relevante. Esses procedimentos incluem a remoção de sinais contaminantes, bem como a extração seletiva das componentes do sinal de interesse, de modo a preservar as características fundamentais associadas à atividade cerebral que se pretende investigar (NIEDERMEYER; SILVA,2010).

4.2.1 Inteligência Artificial aplicada a sinais bioelétricos

As técnicas de Inteligência Artificial (IA) dependem fundamentalmente da qualidade e da representação dos dados fornecidos como entrada, os quais podem assumir diversas formas, como imagens, sinais acústicos ou sinais biológicos, incluindo os sinais eletroencefalográficos. No caso dos sinais de EEG, que são de natureza não estacionária e apresentam grande complexidade, o desafio é ainda maior devido à sua suscetibilidade a ruídos, variações interindividuais e múltiplas fontes de origem neural e artefactual (GUYON; ELISSEEFF,2003).

A automação do processo de reconhecimento de padrões em sinais de EEG é uma tarefa de alta complexidade, influenciada por múltiplas variáveis interdependentes. Os padrões observáveis nesses sinais representam, muitas vezes, respostas fisiológicas a eventos bioquímicos gerados ou propagados pelo organismo. Identificar e classificar esses padrões de forma robusta requer a aplicação de técnicas de processamento de sinais que viabilizem a extração de características relevantes, etapa fundamental

para o desempenho dos algoritmos de IA (AKIN,2002).

Esse processo, denominado extração ou seleção de características (*feature extraction ou feature selection*), visa destacar as informações mais significativas do sinal bruto, facilitando a posterior tarefa de classificação. As abordagens para extração de características podem ser agrupadas, de maneira geral, em dois domínios principais:

- **Domínio estatístico**, que inclui medidas como média, variância, entropia, entre outras;
- **Domínio da frequência**, que envolve análise espectral via transformadas como Fourier e Wavelet, permitindo decompor o sinal em componentes frequenciais associadas às bandas delta δ , teta θ , alfa α e beta β . (FAUST et al.,2015).

Além da extração de características, o uso de Redes Neurais Artificiais exige a definição de estratégias adequadas de treinamento e validação, uma vez que a performance da rede está diretamente relacionada à representação dos dados de entrada e ao ajuste ótimo dos seus parâmetros internos (pesos e biases).

A relação entre processamento de sinais, extração de características e desempenho de RNAs é crítica em aplicações de suporte ao diagnóstico, como no reconhecimento de estados patológicos (por exemplo, epilepsia, Alzheimer, sonolência), onde a acurácia depende da capacidade do modelo de distinguir padrões fisiológicos relevantes (LOTTE et al.,2007; SUBASI,2007).

4.2.2 Inteligência Artificial - Ferramentas auxiliares

Alguns métodos matemáticos são particularmente úteis na área de inteligência artificial. RNA é a técnica de IA aplicada no desenvolvimento desta tese. Para encontrar o custo mínimo de uma RNA, o método aplicado é o Gradiente Descendente. Trata-se de um método preditivo, cujo principal objetivo é a busca por uma solução ótima, ou seja, aquela que viabiliza a execução do processo com o menor

erro, parâmetro que mede a distância entre o valor de saída idealizado e aquele efetivamente encontrado

Os modelos, algoritmos e estratégias usadas em IA são suportados por ferramentas matemáticas de ampla aplicação.

Regressão linear e Custo

A técnica de regressão linear constitui uma abordagem fundamental na modelagem preditiva, cuja finalidade é ajustar uma função linear $h_\theta(x)$ que melhor represente a relação entre variáveis independentes x e uma variável dependente y . Essa função, também chamada de hipótese, na sua forma generalizada, é expressa por (HASTIE; TIBSHIRANI; FRIEDMAN,2009):

$$h_\theta(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \cdots + \theta_n x_n = \sum_{j=0}^n \theta_j x_j \quad (4.1)$$

Onde:

- $h_\theta(x)$: É a hipótese, que representa a função de predição ou estimativa da variável dependente;
- θ_j : é um coeficiente do modelo de regressão. Esses valores são ajustados durante o treinamento para minimizar o erro.
- x_j : São os atributos ou variáveis independentes da entrada. Para incluir o termo de bias, define-se $x_0 = 1$.
- $\theta_j x_j$: Cada termo da soma representa a contribuição de uma característica ponderada pelo seu parâmetro.
- $\sum_{j=0}^n \theta_j x_j$: Soma de todos os produtos $\theta_j x_j$, desde $j = 0$ até $j = n$, formando a saída do modelo.

Na sua forma simplificada, essa hipótese é expressa por:

$$h_\theta(x) = \theta_0 + \theta_1 x \quad (4.2)$$

No contexto de aprendizado de máquina supervisionado, deseja-se que essa função aproxime o valor verdadeiro y de maneira ótima, minimizando o erro quadrático entre a previsão do modelo e os valores reais. Esse erro para a i -ésima amostra do conjunto de treinamento é dado por:

$$\text{Erro}^{(i)} = \left(h_{\theta}(x^{(i)}) - y^{(i)} \right)^2 \quad (4.3)$$

A Função de Custo da regressão linear

A medida agregada desse erro para todas as m amostras do conjunto de dados é representada pela função de custo ($J(\theta)$), comumente definida como o erro quadrático médio (MSE), que aqui está sendo multiplicado por $\frac{1}{2}$, que corresponde ao seu fator de normalização. $J(\theta)$ é expresso por

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m \left(h_{\theta}(x^{(i)}) - y^{(i)} \right)^2 \quad (4.4)$$

Onde:

- $J(\theta)$: É a função de custo;
- m : Número de amostras no conjunto de dados;
- $h_{\theta}(x^{(i)})$: Predição do modelo para a i -ésima amostra;
- $y^{(i)}$: Valor real da i -ésima amostra;
- $\frac{1}{2}$: Fator de normalização;
- $\left(h_{\theta}(x^{(i)}) - y^{(i)} \right)^2$: Erro quadrático de uma amostra.

Gradiente descendente

O gradiente descendente é uma técnica algébrica iterativa, amplamente utilizada para encontrar o ponto de mínimo de uma função real de múltiplas variáveis. Sua

principal aplicação em redes neurais artificiais consiste em minimizar a função de custo, ajustando os parâmetros da rede de modo a reduzir progressivamente o erro entre a saída predita e a saída esperada. Essa abordagem se mostra particularmente eficaz em problemas de otimização, mesmo quando a função a ser minimizada apresenta múltiplos parâmetros e elevada complexidade computacional (BISHOP,2006).

A atualização dos parâmetros θ_j ocorre a cada interação, em conformidade com a equação 4.5

$$\theta_j := \theta_j - \alpha \cdot \frac{\partial J(\theta)}{\partial \theta_j} \quad (4.5)$$

Em que α representa a taxa de aprendizagem do processo.

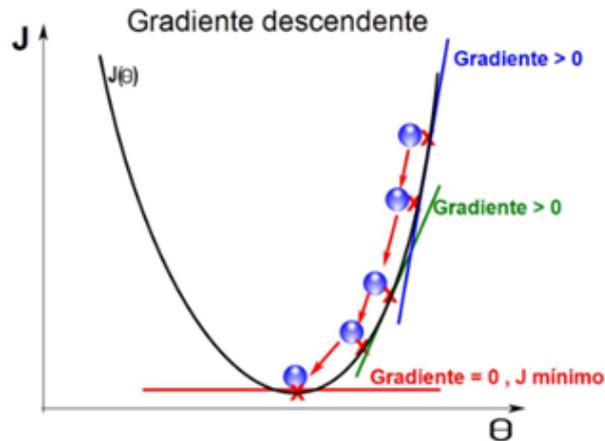
Como exemplo, a Figura 4.7 mostra um modelo de treinamento simples, com entradas e respectivas saídas, devidamente relacionadas. Seja $J(\theta) = J(\theta_0, \theta_1)$. A aplicação do gradiente descendente é iniciada, atribuindo-se aos parâmetros θ_0 e θ_1 dois valores aleatórios, para os quais se calcula o custo $J(\theta) = J(\theta_0, \theta_1)$. Uma vez que o resultado encontrado não corresponda ao valor mínimo da função, atribui-se nova dupla de valores aos parâmetros θ_0 e θ_1 , para os quais mais uma vez se calcula o custo. Esta sequência de operações se repete, até que o valor mínimo da função de custo $J(\theta_0, \theta_1)$ seja alcançado, ou outro atributo de limitação seja imposto, como por exemplo um número máximo de interações. Na prática, essa operação de atualização dos valores de θ_0 e θ_1 consiste num laço recursivo, que pode ser expresso matematicamente por

$$\begin{aligned} \theta_0 &= \theta_0 - \alpha \frac{\partial}{\partial \theta_0} J(\theta_0, \theta_1), \text{ com execução simultânea a } \theta_1. \\ \theta_1 &= \theta_1 - \alpha \frac{\partial}{\partial \theta_1} J(\theta_0, \theta_1), \text{ com execução simultânea a } \theta_0. \end{aligned} \quad (4.6)$$

4.2.3 Transformadas Wavelet

A transformada *Wavelet* (WT) permite a decomposição de um sinal num conjunto de sinais de base, denominados de *Wavelet*. Esses sinais de base são derivados de uma *wavelet*-mãe por operações de escalonamento e deslocamento, resultando em

Figura 4.7: Gradiente descendente.



Fonte: (Acervo do auto, 2025).

uma família de funções base que representam diferentes resoluções do sinal.

O conceito fundamental de *wavelets* remonta ao trabalho de Alfred Haar em 1909, que introduziu a base ortonormal hoje conhecida como *wavelet* de Haar. Contudo, foi apenas nas décadas de 1980 e 1990 que o campo se consolidou, graças às contribuições de Jean Morlet, que introduziu a primeira wavelet com boa localidade em tempo e frequência, e de Yves Meyer, que estabeleceu bases matemáticas rigorosas. Em 1988, Stéphane Mallat formalizou a Análise Multirresolução (MRA), conectando *wavelets* e a Transformada Rápida de Wavelet (FWT) (AL-FAHOUM; AL-FRAIHAT,2014).

Desde então, pesquisadores como Ingrid Daubechies, Ronald Coifman e Victor Wickerhauser têm proposto novas famílias de *wavelets* e algoritmos eficientes, muitos dos quais foram incorporados a ambientes computacionais amplamente utilizados, como o Matlab (DAUBECHIES,1992).

A WT pode ser contínua (CWT) ou discreta (DWT). A CWT é expressa por

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (4.7)$$

Onde:

- $x(t)$: Sinal original a ser decomposto no domínio do tempo.
- $\psi(t)$: Função *wavelet*-mãe, origem de todas as outras wavelets geradas.

- ψ^* : Conjugado complexo da *wavelet*.
- $a \in \mathbb{R}^+ - 0$: Parâmetro de escala, que controla a dilatação ou compressão da *wavelet*.
- $b \in \mathbb{R}$: Parâmetro de **translação**, que determina a posição da *wavelet* no tempo.
- $\frac{1}{\sqrt{|a|}}$: Fator de normalização que garante conservação de energia entre as diferentes escalas.
- $\psi\left(\frac{t-b}{a}\right)$: *wavelet*-filha, que é uma versão escalada e transladada da *wavelet*-mãe.

A DWT é expressa por

$$DWT_{j,k} = \sum_n x(n) \psi_{j,k}(n) \quad \text{com} \quad \psi_{j,k}(n) = 2^{-j/2} \psi(2^{-j}n - k) \quad (4.8)$$

onde:

- $x(n)$: Sinal discreto no tempo (amostrado).
- $\psi_{j,k}(n)$: Conjunto de *wavelets*-filhas, derivadas da *wavelet*-mãe.
- $j \in \mathbb{Z}$: Índice de escala, que define o nível de resolução.
- $k \in \mathbb{Z}$: Índice de translação, que define o deslocamento temporal.
- $\psi(2^{-j}n - k)$: Versão escalada e transladada da *wavelet*-mãe.
- $2^{-j/2}$: Fator de normalização, essencial para garantir a ortonormalidade entre as *wavelets*-filhas.
- A soma realiza a correlação entre o sinal e a *wavelet*-filha correspondente à escala j e translação k .
- O resultado $DWT_{j,k}$: é o coeficiente da transformada discreta, representando a presença da *wavelet* naquela escala e posição no sinal (MISITI et al.,2020).

Aplicação da Transformada wavelet

A transformada *wavelet* é uma ferramenta matemática que permite representar sinais em múltiplas escalas de tempo e frequência de forma simultânea, o que a torna particularmente eficaz para a análise de sinais não-estacionários. Diferentemente da transformada de Fourier, que utiliza funções senoidais infinitamente duráveis como base, a transformada wavelet utiliza funções base (wavelets) com suporte compacto, ou seja, localizadas no tempo.

Essa propriedade viabiliza a análise de eventos transitórios e abruptos que ocorrem em instantes específicos, como frequentemente observado em sinais de EEG. A técnica consiste na projeção do sinal sobre versões escaladas e transladadas de uma wavelet-mãe, permitindo a decomposição do sinal em componentes que evidenciam variações em diferentes faixas de frequência e janelas temporais.

Tal abordagem é essencial para tarefas como a identificação de padrões fisiológicos associados a distúrbios neurológicos, onde a presença de fenômenos localizados é de interesse clínico. Portanto, a análise wavelet constitui um recurso valioso no pré-processamento de sinais EEG para aplicações em sistemas de inteligência artificial e auxílio diagnóstico (DAUBECHIES,1990).

A análise wavelet é baseada na decomposição de um sinal a partir de uma função geradora chamada wavelet-mãe, a qual é transformada por escalonamentos (dilatações e compressões) e translações para gerar um conjunto de funções denominadas wavelets-filhas. Cada wavelet-filha está associada a um nível específico de resolução temporal e frequencial, permitindo assim que a decomposição do sinal ocorra em diferentes escalas.

A compressão da wavelet-mãe (escalas menores) favorece a análise de componentes de alta frequência com boa resolução temporal; por outro lado, sua dilatação (escalas maiores) permite boa resolução em baixas frequências, com menor precisão temporal. Esse mecanismo multirresolução torna a análise wavelet particularmente eficaz na identificação de eventos localizados no tempo, especialmente em sinais não-estacionários como o EEG.

Os coeficientes wavelet, calculados por produtos internos entre o sinal e as wavelets-filhas, representam a contribuição de cada componente em diferentes escalas e posições. A partir desses coeficientes, pode-se reconstruir o sinal original ou enfatizar determinadas características, conforme a aplicação.

A escolha da wavelet-mãe adequada é muito importante e depende do padrão que se deseja identificar no sinal. Diversos núcleos já foram propostos e documentados na literatura, como as wavelets de Haar, Daubechies, Symlets e Coiflets. A técnica é amplamente aplicada em tarefas como compressão de dados, remoção de ruídos, detecção de descontinuidades e análise de padrões em sinais fisiológicos (MISITI et al.,2020).

Ao contrário da Transformada de Fourier, cuja base é composta por funções senoidais de suporte infinito, a transformada wavelet trabalha com funções de suporte compacto, o que confere à técnica a capacidade de localizar no tempo as ocorrências frequenciais. Essa característica é particularmente útil na análise de sinais EEG, cuja natureza é altamente dinâmica e não-estacionária (DIBAL; ODU; VEMURI,2019).

A transformada wavelet escolhida foi de Daubechies de 4 pontos. Ela corresponde a um conjunto de wavelets ortogonais, introduzidas por Ingrid Daubechies. Essas wavelets são caracterizadas por um filtro com coeficientes que permitem que o sinal seja decomposto em diferentes escalas, usando uma série de convoluções e subamostragens. Elas podem ser expressas usando filtros passa-baixa e passa-alta associados aos coeficientes de Daubechies. Assim, para realizar a transformada wavelet de Daubechies de um sinal, ele é decomposto em aproximações (A) e detalhes (D), usando convoluções com os filtros passa-baixa e passa-alta, definidos pelos coeficientes h_k e g_k , seguidas de subamostragem. Em cada nível, essa decomposição é expressa por

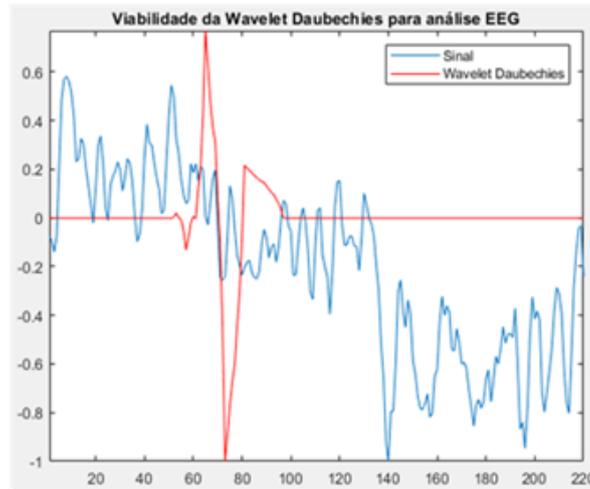
$$\begin{aligned} A_{j+1}[n] &= \sum_k h_k \cdot A_j[2n - k] \\ D_{j+1}[n] &= \sum_k g_k \cdot A_j[2n - k] \end{aligned} \tag{4.9}$$

Onde:

- $A_j[n]$: aproximação do sinal no nível j
- $D_{j+1}[n]$: detalhe extraído no nível $j + 1$
- h_k : coeficientes do filtro passa-baixa (scaling function)
- g_k : coeficientes do filtro passa-alta (wavelet function)
- $2n$: operação de subamostragem (redução pela metade)

A Figura 4.8 apresenta uma wavelet de Daubechies 2 e um sinal de EEG, enquanto a Figura 4.9, um resumo em blocos de sua decomposição.

Figura 4.8: Sinal de EEG e wavelet Daubechies 2.

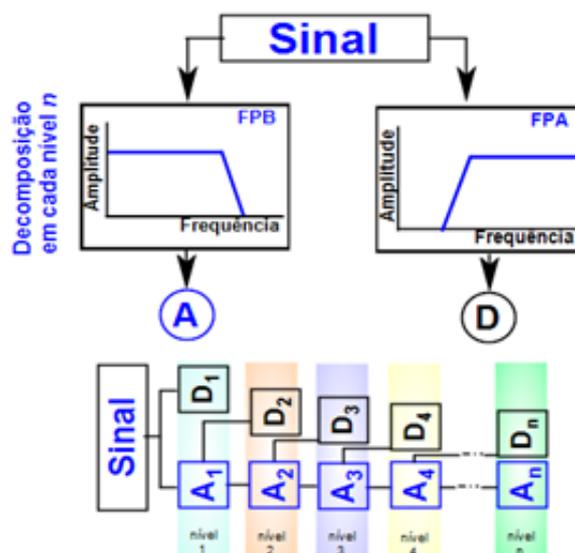


Fonte: (Acervo do autor,2025).

4.3 A atividade cerebral

O processamento cognitivo é resultado de uma atividade cerebral contínua. Ele é dependente de um comportamento característico fundamental: o Acoplamento Neuronal Intrínseco (ANI), que possui um padrão espaço-temporal e desencadeia uma quantidade significativa de reações físico-químicas. Existem evidências de dois tipos distintos de ANI: O primeiro tipo decorre do acoplamento de fase de sinais oscilatórios limitados em banda de frequência, enquanto o outro, de flutuações não

Figura 4.9: Decomposição 4-DWT.



Fonte: (Acervo do autor,2025).

regulares, que surgem como consequência de um conjunto de sinais simultâneos de origens diversas. Os dois modos de acoplamento são diferentes quanto às suas origens, suas dinâmicas e suas supostas influências na produção e ou alteração de transtornos neuropsiquiátricos. Acredita-se que o conceito de Modos de ANI e M-ANI pode sugerir uma estrutura capaz de resumir a dinâmica de interações neurais intrinsecamente geradas em múltiplas escalas espaciais e temporais (ENGEL et al.,2013).

A queda da capacidade cognitiva é um dos primeiros sintomas mais drásticos evidenciados pelos portadores da DA. Ela evolui continuamente, sem que, em significativa parcela dos casos, o diagnóstico da doença tenha sido confirmado, pois o processo investigativo da doença demanda grande quantidade de exames, a exemplo dos clínicos, laboratoriais, de sinais elétricos, de imagem, de análise comportamental por terapeuta especializado, entre outros.

Por isso, a identificação da DA envolve um conjunto considerável de procedimentos, que se complementam à medida que são executados, convergindo ou não. Isto aumenta, ainda mais, a complexidade na definição de parâmetros que garantam o fechamento do diagnóstico. Este dilema traz um problema a ser resolvido: Como di-

agnosticar a DA de maneira mais simples, em meio a tantos fatores que influenciam no seu reconhecimento. E, diante dessa possível identificação, como evoluir para antecipar-se na aplicação de terapias que desacelerem a sua evolução, permitindo uma melhor qualidade de vida aos seus portadores e todos aqueles que o cercam.

A DA é influenciada por muitos fatores, cujos reflexos são sinalizados em diversas regiões do cérebro. Assim, a identificação dessas regiões de maneira específica pode variar, dependendo do estudo, método e propósito utilizado. Esta tese apresenta uma estratégia que viabiliza a redução do tempo para diagnóstico da DA, pela análise dos sinais de EEG de seus portadores. Ela propõe uma ferramenta que avalia um sinal de EEG, extrai dele parâmetros que são aplicados como referência para treinamento de uma RNA adaptativa (RNAA), aplicada para classificação de portadores versus não portadores da DA em todas as fases da doença.

4.4 Identificação de doenças neurológicas através de sinais de EEG

Os sinais de EEG registram mudanças nos padrões de atividade cerebral que podem ser correlacionadas com o declínio cognitivo e diversas demências, inclusive a Doença de Alzheimer. Estudos têm demonstrado que, em pacientes portadores de DA, podem ser observadas as seguintes anormalidades:

1. Redução da potência na banda alfa: Evidenciada predominantemente nas regiões temporal e parietal, essa diminuição está associada a prejuízos nas funções cognitivas e na integração das informações sensoriais (JEONG,2004).
2. Aumento da potência nas bandas delta e teta: Mais acentuado nas regiões temporal e frontal, o aumento nessas bandas pode refletir a desregulação dos processos de ativação cortical, relacionados à progressão da DA (BABILONI et al.,2006).
3. Alterações na coerência: A coerência, que mensura o grau de sincronização

entre diferentes regiões cerebrais, sofre modificações em pacientes com DA, especialmente em áreas temporal e frontal, sugerindo comprometimento na conectividade neuronal.

4. Ocorrência de padrões anormais: Diversos fatores, como variações no estado de alerta, emocional e físico, influenciam os sinais de EEG, complicando a análise e exigindo abordagens multimodais para um diagnóstico preciso.

Diante da complexidade e da variabilidade intrínseca dos sinais de EEG, sua análise para fins diagnósticos demanda considerações múltiplas e a integração com outros métodos de avaliação. Em contextos clínicos, especialmente em países com restrições orçamentárias e de infraestrutura, essa complexidade pode resultar na necessidade de exames complementares de elevado custo e em grande número (JEONG,2004; BABILONI et al.,2006).

4.5 Regiões de aquisição dos sinais de EEG

Conforme o propósito, o sinal de EEG considerado numa análise pode ser mais ou menos relevante, de acordo com o envolvimento da região craniana onde se realizou a aquisição do sinal com a atividade investigada. Sendo assim, a seleção dos eletrodos dos sinais de EEG a serem considerados é importante, de modo que os mesmos contenham dados que possam ser traduzidos em informações relevantes para identificação da doença neurológica sob estudo.

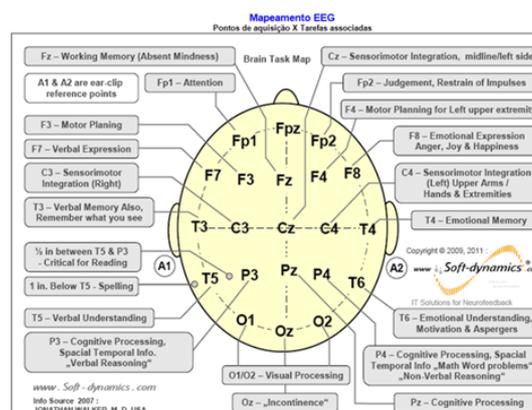
Referente à DA, verifica-se que as algumas regiões do cérebro, apresentadas na Figura 25, reagem com padrões de atividade elétrica passíveis de serem associados à doença (Fonte: Babiloni et al., 2016) (BABILONI et al.,2016). Delas, podem se destacar:

1. **Lobos Temporais (T):** As regiões temporais do cérebro estão relacionadas à memória e ao processamento de informações. Mudanças na atividade elétrica desses lobos estão associadas à progressão da doença de Alzheimer.

2. **Lobos Frontais (F):** As regiões frontais do cérebro estão relacionadas às funções executivas, como planejamento, tomada de decisão e controle inibitório. Alterações na atividade elétrica desses lobos foram relatadas em pacientes com doença de Alzheimer, sugerindo que a análise dos padrões encontrados pode revelar disfunções associadas à doença.
3. **Região Parietal (P):** A região parietal do cérebro está relacionada a coordenação sensorial e atividades que demandam atenção. Alterações na atividade elétrica dessa região podem estar relacionadas a déficits de atenção e processamento sensorial comprometido, como os observados em pacientes com doença de Alzheimer.
4. **Conectividade Inter-hemisférica:** Além do posicionamento dos eletrodos em regiões específicas, a análise da conectividade entre os hemisférios cerebrais também é importante, uma vez que alterações na conectividade inter-hemisférica foram relatadas em pacientes com doença de Alzheimer, podendo refletir disfunções na comunicação entre diferentes regiões do cérebro (BEVILACQUA et al.,2015).

A Figura 4.10 mostra uma relação entre os pontos do Sistema 10-20 e as atividades monitoráveis no momento da aquisição.

Figura 4.10: Pontos de aquisição versus Atividades relacionadas.



Fonte: (DYNAMICS.COM,2023).

”A gente pode morar numa casa mais ou menos, numa rua mais ou menos, e até ter um governo mais ou menos. A gente só não pode amar mais ou menos, sonhar mais ou menos, ser amigo mais ou menos, ter fé mais ou menos e acreditar mais ou menos. Senão, a gente corre o risco de se tornar uma pessoa mais ou menos.”

Chico Xavier.

Capítulo 5

Rede Neural Artificial Adaptável para Identificação da Doença de Alzheimer

Neste capítulo, é apresentada uma Rede Neural Artificial dinâmica (RNA) para reconhecimento de padrões de ondas cerebrais delta δ , teta θ , alfa α e beta β , a partir de um sinal de EEG, previamente processado através de filtros e transformada wavelet discreta de Daubechies (D-DWT). O reconhecimento de padrões em sinais de EEG se mostra muito útil para identificação de patologias. Um bom exemplo dessa aplicação pode ser vista em (RODRIGUES et al.,2002).

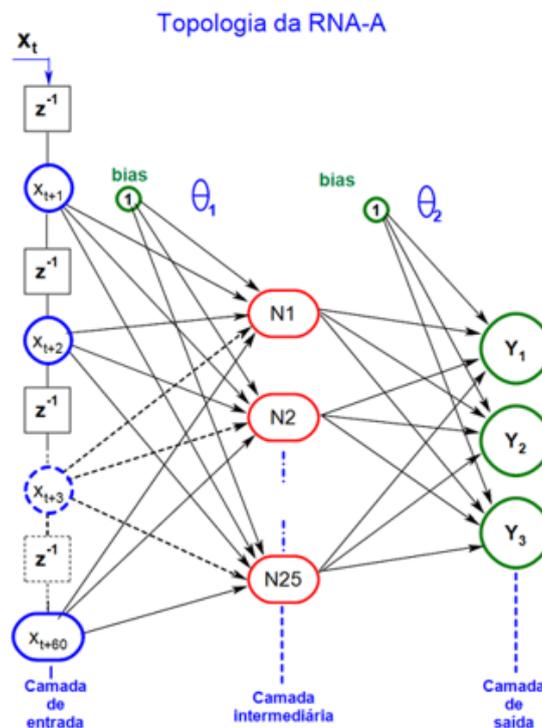
Os sinais de EEG usados neste trabalho foram obtidos na plataforma de acesso público OpenNeuro (MILTADOUS,2023). Esta base de dados foi liberada para acesso em fevereiro de 2023. Consiste numa base com sinais de EEG de 88 indivíduos, sendo 36 deles diagnosticados com a Doença de Alzheimer (grupo DA); 23, com Demência Frontotemporal (grupo FTD) e 29 indivíduos saudáveis (grupo HE). A aquisição dos sinais aconteceu a uma frequência de amostragem de 500 Hz e resolução de $10\mu V/mm$, realizada por uma experiente equipe de neurologistas do Departamento de Neurologia do Hospital Geral da cidade de Thessaloniki, ao norte da Grécia. O equipamento de EEG utilizado foi o Nihon Kohden 2100®, com 19

eletrodos conectados ao couro cabeludo (Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 e O2), conforme o sistema internacional 10-20, apresentado na Seção 4.1.2; os 2 eletrodos de referência (A1 e A2) posicionados nas mastoides para verificação de impedância, conforme recomendação do manual do referido equipamento. Informações complementares sobre a base de dados estão disponíveis no Anexo A.

5.1 Entrada do sinal de EEG na rede

A entrada do sinal na primeira camada da RNA é realizada serialmente. A janela de amostragem tem o mesmo tamanho da camada de entrada da RNA. O processo de amostragem é iniciado quando toda a janela está preenchida com as amostras x_t , Figura 5.1.

Figura 5.1: RNA - Entrada do sinal de EEG.



Fonte: (Acervo do autor,2025).

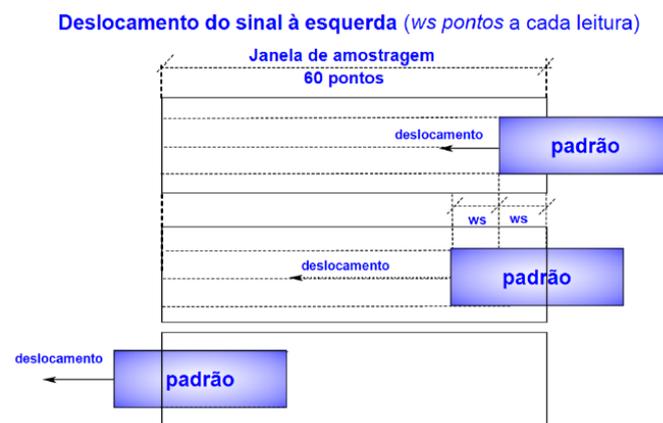
Depois da primeira amostragem, todas as demais são realizadas por desloca-

mento à esquerda das amostras contidas na amostragem anterior. Nas etapas de treinamento e operação, o tamanho deste deslocamento é definido pelo parâmetro ws , (*window shift*). Seu ajuste é definido na etapa de parametrização da rede, com valor correspondente a um percentual da janela de amostragem. Após a primeira amostragem, todas as demais são realizadas com memória, ou seja, uma parcela de suas amostras é remanescente da amostragem anterior.

A RNA foi concebida para ser flexível e facilmente adaptável para identificação de diferentes padrões de sinais biológicos. Nesta aplicação, ela está dedicada aos sinais neurológicos, tendo como entrada um sinal de EEG, previamente processado. Sua primeira camada, na etapa de treinamento da rede, recebe um sinal que é composto por padrões cerebrais, nas faixas de frequência delta δ , teta θ , alfa α e beta β .

A leitura dos dados na camada de entrada segue um algoritmo que desloca o sinal sob análise dentro da janela de amostragem, como mostra a Figura 5.2.

Figura 5.2: Deslocamento do sinal na camada de entrada da RNA.



5.2 Propagação dos dados através das camadas da RNA

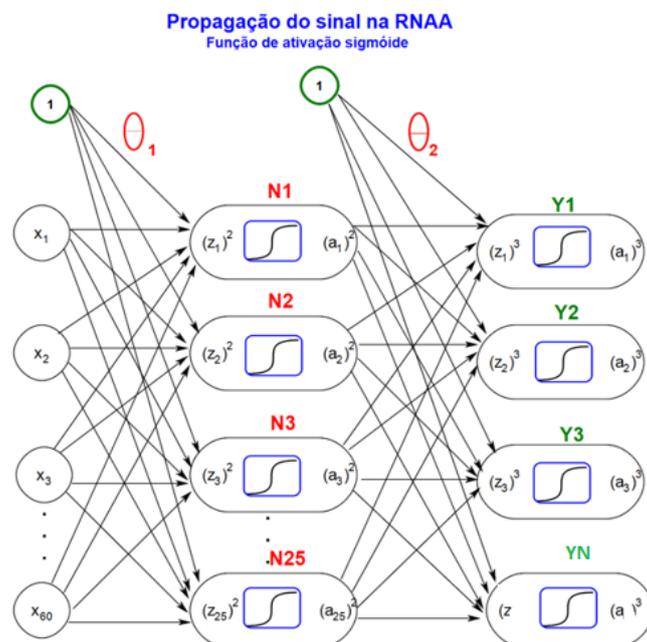
Em uma RNA, a partir da primeira camada intermediária, os dados são transferidos para as demais camadas através de uma componente essencial, denominada

função de ativação. Na RNA, a função de ativação introduz não linearidade nas saídas dos neurônios, permitindo que a rede aprenda relações complexas e não lineares entre as entradas e saídas. Sem ela, a capacidade de modelagem de uma RNA ficaria radicalmente limitada. Exemplos de funções de ativação são apresentados na Seção 3.5.5.

No projeto de uma RNA, a escolha dessa função é estratégica, por sua influência direta com a performance da rede (HAYKIN,2001;GOODFELLOW;BEN-GIO; COURVILLE,2016).

Uma RNA com N neurônios em sua camada de saída e com todos os seus neurônios ativados por uma função sigmóide é apresentada na Figura 5.3. Nesta representação, z_i^n é o potencial de ativação do neurônio i na camada n , enquanto a_i^n é a respectiva resposta do neurônio à ativação recebida. Sendo assim, o vetor de componentes $a_1^3, a_2^3, a_3^3, a_N^3$ corresponde à saída de RNA.

Figura 5.3: RNA com propagação ativada por função sigmoide.



Fonte: (Acervo do autor,2025).

5.3 Pré-processamento do sinal de EEG

A análise e classificação de sinais de EEG para a identificação de padrões associados a condições neurológicas dependem criticamente do pré-processamento adequado do sinal. Métodos tradicionais de filtragem passa-banda, baseados em técnicas como os filtros *Butterworth* ou FIR, oferecem uma separação direta das bandas de frequência de interesse (delta δ , teta θ , alfa α , beta β), com vantagens em termos de simplicidade e eficiência computacional. Contudo, estas abordagens podem apresentar limitações na resolução temporal, prejudicando a identificação de eventos transitórios (SUBASI,2007).

Em contrapartida, a transformada wavelet possibilita uma decomposição multirresolução do sinal, fornecendo uma representação conjunta no domínio do tempo e da frequência. Essa propriedade é particularmente benéfica para sinais de EEG, que são intrinsecamente não estacionários e frequentemente apresentam descontinuidade em seus padrões. Entretanto, o método wavelet demanda maior poder computacional e uma cuidadosa seleção de parâmetros, como a wavelet-mãe, a ordem e o número de níveis de decomposição (SANEI; CHAMBERS,2007; SUBASI,2007).

Diante dessas considerações, este trabalho propõe um esquema de pré processamento híbrido, no qual o sinal de EEG é submetido a ambos os métodos – filtro passa-faixa e análise wavelet, de modo a extrair as características de cada faixa de frequência. Em seguida, o critério de seleção é a energia presente em cada banda; ou seja, o método que preservar a maior energia do sinal na banda de interesse será utilizado para a etapa subsequente de classificação por redes neurais artificiais. Tal abordagem possibilita a avaliação comparativa e a escolha do melhor método para a extração de características relevantes, considerando tanto a resolução em frequência quanto em tempo.

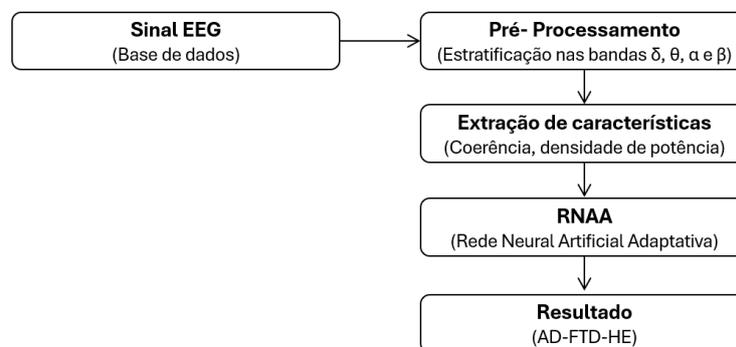
A potência espectral, que pode ser calculada para cada banda, é dada por: $P(f) = |X(f)|^2$, onde $X(f)$ representa a transformada de Fourier do sinal. Essa métrica servirá como base para a seleção do método mais adequado.

Em resumo, o processamento adotado é híbrido. Ao combinar as abordagens de

filtragem e transformada wavelet, busca-se maximizar a qualidade do pré-processamento dos sinais de EEG, proporcionando uma base robusta para a subsequente tarefa de classificação em sistemas de apoio diagnóstico (SANEI; CHAMBERS,2007; SUBASI,2007).

O sistema para identificação de portadores da doença de Alzheimer é resumido em blocos na Figura 5.4, que apresenta um fluxo operacional, desde a entrada do sinal de EEG até a identificação do perfil de seu portador (HE - AD - FTD).

Figura 5.4: Macro fluxo do Sistema.



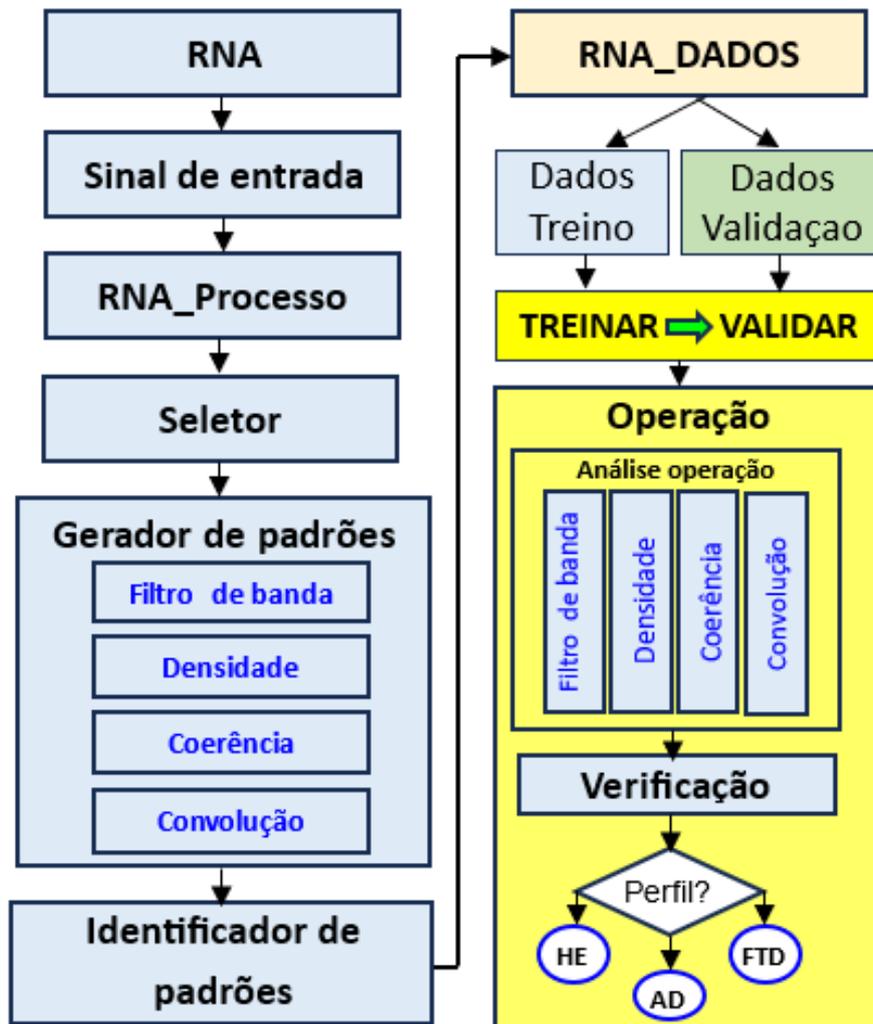
Fonte: (Acervo do autor,2025).

Esse fluxo de operação é cumprido através dos módulos de *software* apresentados na Figura 5.5, que é a referência para descrição das etapas de processamento.

A rede é iniciada no primeiro módulo da Figura 5.5, RNA. Depois, continua através dos módulos abaixo relacionados, com as respectivas operações:

1. **Sinal de entrada:** O sinal de EEG é recebido, oriundo dos pontos T3 ou T4, e armazenado em memória.
2. **RNA Processo:** As duas RNAs (RNA-1 e RNA-2) são configuradas, com definição das respectivas topologias, função de transferência, parâmetros de treinamento (número de épocas, taxa de aprendizagem, erro) e validação, seguidas da efetiva criação;
3. **Seletor:** Seleciona 3 minutos do sinal EEG armazenado em memória e entrega ao módulo Gerador de padrões.

Figura 5.5: Módulos de software do Sistema.



Fonte: (Acervo do autor,2025).

4. **Gerador de padrões:** Implementa uma estratégia híbrida para pré-processamento do sinal, usando filtro passa-faixa e análise wavelet Daubechies 2. O sinal com maior energia obtido entre os dois métodos é selecionado como fonte para extração dos sinais de densidade de potência (dsp) e coerência T3-T4. Estes dois sinais são as referências para a identificação dos padrões de treinamento.
5. **Identificador de padrões:** Extrai os padrões de treinamento, a partir dos sinais de densidade de potência e coerência T3-T4. Posteriormente, estes padrões são aplicados às redes implementadas, RNA-1 e RNA-2 (Exemplos de sinais de referência para extração dos padrões de treinamento são apresen-

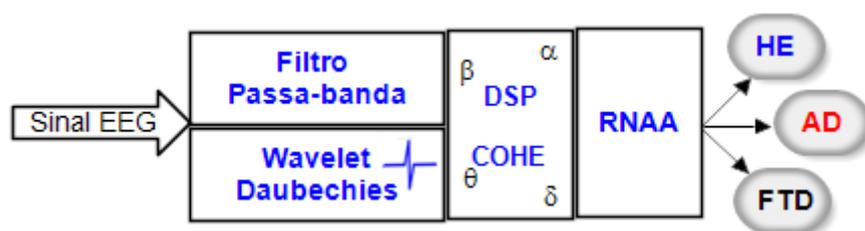
tados no Apêndice A).

6. **RNA_Dados:** Neste módulo, são implementadas as redes RNA-1 e RNA-2. Os dados são preparados para o treinamento e validação das redes, através de balanceamento e embaralhamento, conforme se explica na Seção 5.6. Após a validação, as redes são liberadas para a fase de operação.
7. **Operação:** Na operação, primeiramente, os sinais de EEG de indivíduos sob teste são pré-processados, sendo extraídos seus padrões de coerência e densidade de potência, estratificados por banda de frequência. Depois, esses padrões são submetidos à RNA-1, sendo identificados os perfis HE, FTD ou AD dos respectivos portadores.

5.3.1 A extração dos padrões de densidade e coerência do sinal EEG

A Figura 5.6 apresenta os blocos 'Filtro Passa-banda', 'Wavelet Daubechies'. Estes dois blocos são responsáveis pela estratégia híbrida de estratificação do sinal nas bandas delta δ , teta θ , alfa α e beta β . O sinal de EEG é processado por ambos, sendo avaliada a energia nos respectivos sinais de saída desses blocos. Aquele que possuir maior energia é selecionado para extração dos padrões de densidade de potência e coerência, através do módulo 'DSP COHE'. O sinal de saída deste bloco é processado pela RNAA, para identificação do perfil de seu portador.

Figura 5.6: Blocos de pré-processamento e RNAA.

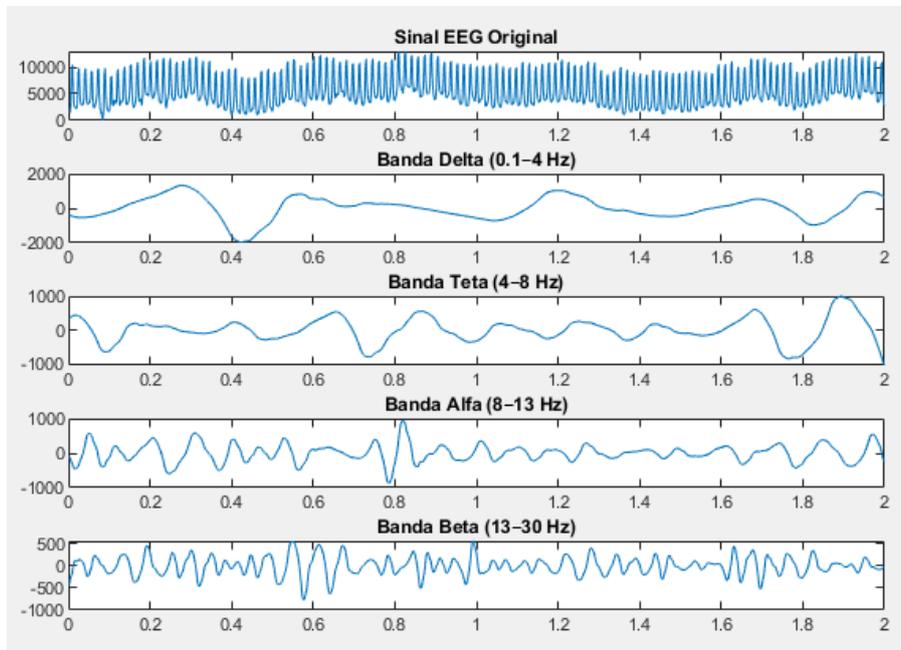


Fonte: (Acervo do autor,2025).

Um exemplo de processamento por análise wavelet é visto na Figura 5.7, onde

um pequeno intervalo de EEG (2 segundos) é estratificado em suas bandas delta δ , teta θ , alfa α e beta β .

Figura 5.7: Análise wavelet em sinal EEG com duração de 2s.



Fonte: (Acervo do autor,2025).

5.4 RNA-1 e RNA-2

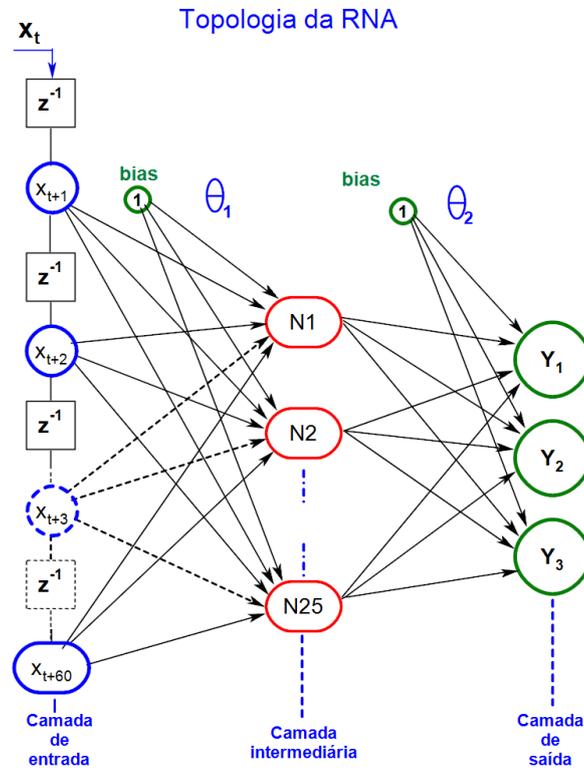
São duas redes neurais artificiais dinâmicas, RNA-1 e RNA-2, implementadas no módulo RNA_DADOS, da Figura 5.5. RNA-1 tem o propósito de discriminação entre os perfis AD, FTD e HE; RNA-2, de discriminação entre os perfis AD1 (AD no estágio inicial da doença) e AD2-3 (AD nos estágios intermediário e avançado da doença, respectivamente).

5.4.1 RNA-1: Identificação dos perfis HE, AD e FTD

Trata-se de um mapeamento $\mathbb{R}^{60} \rightarrow \mathbb{R}^3$, conforme abordagem realizada na Seção 3.5.2. Assim, a topologia da RNA-1 foi idealizada com 60 nós na camada de entrada, 25 neurônios na camada intermediária e 3 neurônios na camada de saída. Note-se

que o número de neurônios na camada de saída da rede deve ser suficiente para discriminar todos os perfis. A RNA-1 é apresentada na Figura 5.8.

Figura 5.8: Topologia de RNA-1.



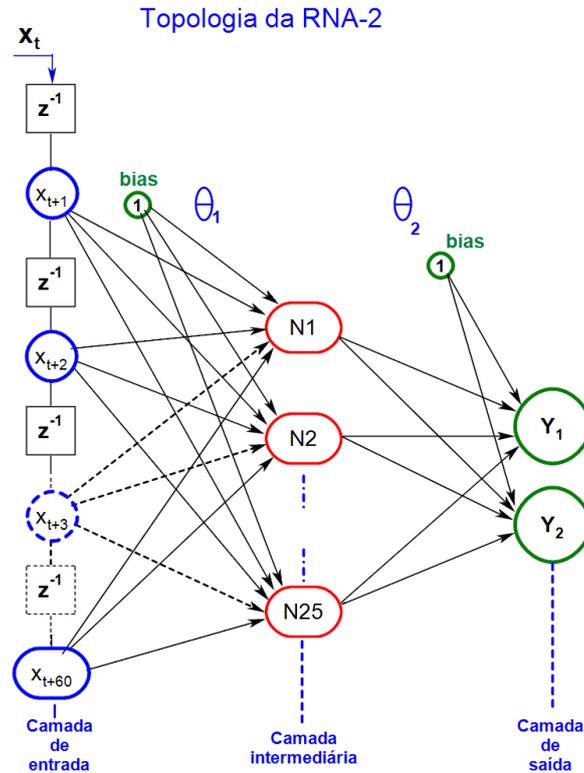
Fonte: (Acervo do autor,2025).

5.4.2 RNA-2: Identificação dos perfis AD1 e AD2-3

Trata-se de um mapeamento $\mathbb{R}^{60} \rightarrow \mathbb{R}^2$, conforme abordagem na Seção 3.5.2. Assim, a topologia da RNA-2 foi idealizada com 60 nós na camada de entrada, 25 neurônios na camada intermediária e 2 neurônios na camada de saída. Note-se que o número de neurônios na camada de saída da rede deve ser suficiente para discriminar apenas 2 perfis, porque o perfil AD2-3 reúne as características dos perfis 2 e 3, simultaneamente. Note-se que, neste caso, a rede também poderia ser implementada com apenas 1 neurônio na camada de saída. A RNA-2 é apresentada na Figura 5.9.

As topologias das RNAs apresentadas são, por definição, inspiradas na estrutura do cérebro humano. Nelas, o sinal de entrada se propaga por neurônios, que formam

Figura 5.9: Topologia de RNA-2.



Fonte: (Acervo do autor,2025).

diversas redes neuronais. O propósito é a identificação de sinais através de padrões previamente definidos.

A camada de entrada foi projetada com 60 nós. Para maior simplicidade operacional, sem prejuízo de sua performance, tem uma única camada intermediária com 25 neurônios (PANCHAL; PANCHAL,2014). A camada de saída tem o número de neurônios definido pela quantidade de perfis a discriminar. Nos casos das redes RNA-1 e RNA-2, 3 e 2 neurônios, respectivamente. Na camada intermediária, verificou-se que 25 é um número que viabiliza o treinamento e operação de ambas as RNAs, com boa performance. θ_1 e θ_2 são as matrizes de pesos, que definem a força sináptica entre os diversos neurônios da rede.

5.5 Inicialização de RNA-1 e RNA-2

A etapa de inicialização das redes RNA-1 e RNA-2 constitui um passo essencial para garantir um treinamento eficiente e a estabilidade da aprendizagem, sobretudo em aplicações voltadas à classificação de sinais de EEG para identificação da Doença de Alzheimer. Trata-se do momento em que se define a estrutura e o funcionamento da arquitetura da rede, contemplando parâmetros como o número de camadas, a quantidade de neurônios por camada, as funções de ativação, a taxa de aprendizagem e os critérios de parada, como o número máximo de épocas ou a tolerância mínima ao erro.

Antes do início do treinamento, é fundamental que os dados utilizados, oriundos da base OpenNeuro e referentes a sujeitos com Doença de Alzheimer (AD), Demência Frontotemporal (FTD) e indivíduos saudáveis (HE), sejam devidamente pré-processados. Essa preparação envolve a aplicação de técnicas para extração das características previamente definidas, como a densidade espectral de potência e a coerência entre os pontos T3 e T4. Essas medidas são estratificadas nas bandas de frequência delta δ , teta θ , alfa α e beta β .

A formatação final do conjunto de dados de entrada para o treinamento resulta em um vetor composto por sinais que descrevem as características extraídas, representativas dos perfis HE, AD e FTD. Essa estrutura padronizada é essencial para que a RNA inicie seu processo com amostras coerentes dos dados. Uma inicialização bem conduzida da rede contribui diretamente para a convergência do algoritmo de treinamento e para a generalização do modelo, especialmente quando este é submetido à etapa de teste com dados distintos dos utilizados no aprendizado.

5.6 Treinamento e validação de RNA-1 e RNA-2

A etapa de treinamento e validação das redes neurais RNA-1 e RNA-2 constitui um dos momentos mais críticos do processo de modelagem, sendo decisiva para a capacidade da rede em aprender padrões relevantes e generalizá-los a novos dados.

Cada rede recebe conjuntos específicos de dados, estrategicamente selecionados de acordo com o objetivo . A RNA-1 é treinada para distinguir indivíduos com AD daqueles com FTD e sujeitos saudáveis HE. Já a RNA-2 visa discriminar entre os diferentes estágios da Doença de Alzheimer, diferenciando os casos iniciais (AD1) dos moderado e grave, agrupados sob o rótulo AD23.

Os dados de entrada utilizados em ambas as redes são previamente processados pelo módulo *RNA_DADOS*. Através dele, as características de densidade espectral de potência (DSP) e coerência (COHE) entre os pontos T3 e T4 são extraídas e organizadas em vetores representativos, por meio do módulo denominado *Gerador de Padrões*. Essas características são selecionadas com base na literatura, por serem relevantes na identificação de alterações eletrofisiológicas associadas a doenças neurodegenerativas (BABILONI et al.,2016).

A composição dos conjuntos de treinamento é cuidadosamente balanceada em cada rede, garantindo o mesmo número de amostras para cada classe (AD, FTD e HE, em RNA-1; AD1 e AD23, em RNA-2). Essa estratégia busca mitigar o risco de viés de classe, no qual uma rede se torna mais propensa a classificar um grupo em detrimento dos demais, prejudicando a equidade e a acurácia do modelo. Além disso, os dados são submetidos a um processo de embaralhamento aleatório (*shuffling*) antes de cada operação de treinamento. Tal técnica é crucial para evitar que a rede aprenda padrões artificiais relacionados à sequência de apresentação dos dados, o que pode provocar o problema de sobreajuste (*overfitting*) e comprometer sua capacidade de generalização em cenários reais (GOODFELLOW; BENGIO; COURVILLE,2016).

Por fim, a etapa de validação paralela ao treinamento permite monitorar o desempenho da rede em dados não vistos durante o aprendizado, funcionando como um indicativo da estabilidade do modelo e de sua habilidade de generalização. A correta condução dessa etapa é determinante para a robustez da RNA, quando aplicada a novos dados clínicos.

5.6.1 RNA-1 e RNA-2: Execução do treinamento e validação

Na rede RNA-1, os perfis AD, FTD e HE estão associados às saídas 1, 2 e 3, respectivamente; Na rede RNA-2, o perfil AD1 está associado à saída 1, enquanto o perfil AD23 está associado à saída 2. O módulo RNA.Dados executa a preparação dos dados para viabilizar o treinamento e validação das redes RNA-1 e RNA-2, em conformidade com as recomendações técnicas apresentadas na Seção 5.6.

a RNA é inicializada com pesos aleatórios, sendo calculado seu custo inicial. Na sequência, executa-se o algoritmo gradiente descendente, quando todos os pesos da RNA são calculados recursivamente, até que se encontre o menor custo possível, que é estimado para o número máximo de iterações, definido na inicialização.

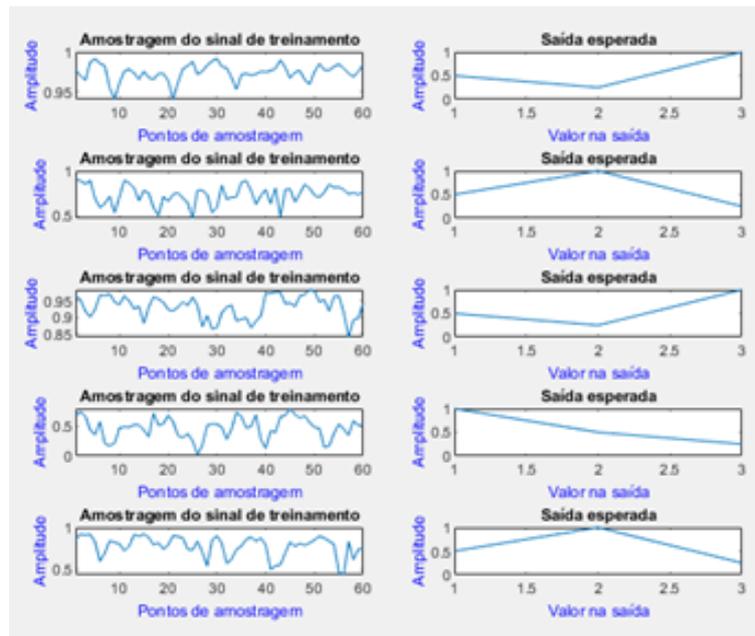
Quanto ao critério para adaptação, ficou definido:

- Grau de confiança é um parâmetro que mede o nível de segurança que uma RNA tem em relação às predições que realiza. Ele é associado a cada uma das saídas da RNA. Quanto mais próximo de 1 for a saída, maior é o grau de confiança a ela associado.
- A rotina de adaptação é habilitada, toda vez que o grau de confiança de qualquer uma das saídas da rede permanecer inferior a 50% por 20 avaliações consecutivas.
- Se a rotina de adaptação é habilitada, um ajuste parcial dos pesos é executado.

As Figura 5.10 apresenta amostragens de treinamento de RNA-1. Nesta etapa, a saída esperada para cada evento de treinamento fica definida por vetores de 3 componentes reais, que variam no intervalo fechado entre 0 e 1 [0,1]. Para a RNA-1, as componentes idealizadas para cada saída assumem os valores 0.25, 0.5 ou 1. O treinamento da rede consiste em ajustar suas matrizes de pesos θ_1 e θ_2 , de modo que sejam obtidas as saídas esperadas para cada evento de treinamento com a menor margem de erro possível.

Assim, a saída esperada para cada evento de treinamento define que o padrão aguardado para a amostragem é aquele definido por sua componente de maior valor.

Figura 5.10: RNA-1: Amostragens de treinamento.



Fonte: (Acervo do autor,2025).

Portanto, nas amostragens da Figura 5.10, onde 3, 2, 3, 1 e 2 são definidas como saída esperada, os perfis correspondem a HE, FTD, HE, AD e FTD, respectivamente. No Apêndice A, são apresentadas 50 de 288 amostragens de treinamento, realizadas em RNA-1.

Na validação, são listadas as saídas esperada e obtida para cada evento. As Figuras 5.11, 5.12 e 5.13 juntas apresentam 15 eventos de validação de RNA-1.

A Figura 5.14 apresenta a Curva de erro no treinamento e validação de RNA-1, enquanto a Figura 5.15, o seu Erro médio em cada neurônio da camada de saída.

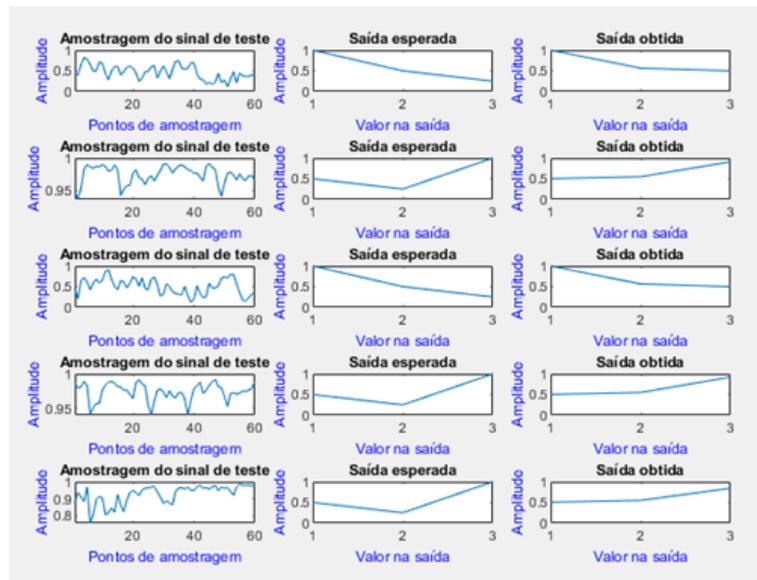
A Figura 5.18 apresenta a Curva de erro no treinamento e validação de RNA-2, enquanto a Figura 5.19, o seu Erro médio em cada neurônio da camada de saída.

Assim, em conformidade com o estabelecido para a rede RNA-1, os eventos de validação apresentados nas Figuras 5.11, 5.12 e 5.13 são resumidos na Tabela 5.1.

Nas tabelas de resumo da validação para as redes RNA-1 e RNA-2, as colunas tem o significado abaixo listado:

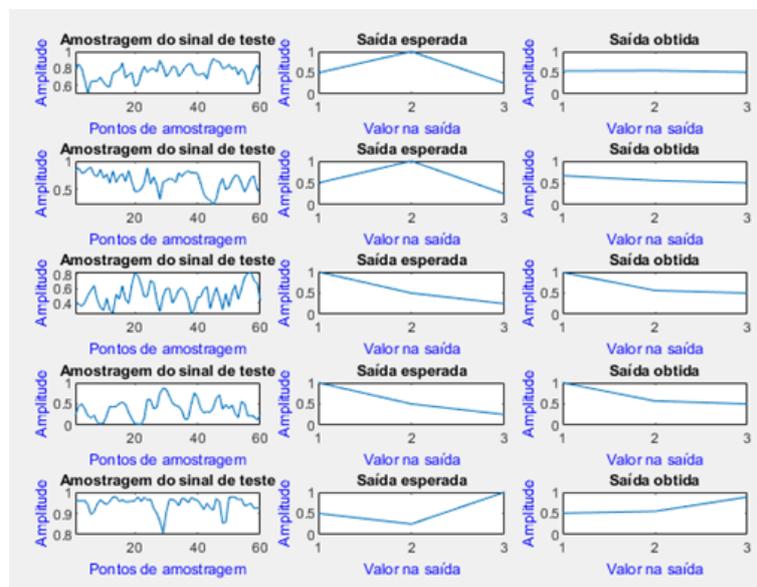
- **A coluna No.** identifica a sequência do teste;

Figura 5.11: RNA-1: Amostras de validação (1 a 5).



Fonte: (Acervo do autor,2025).

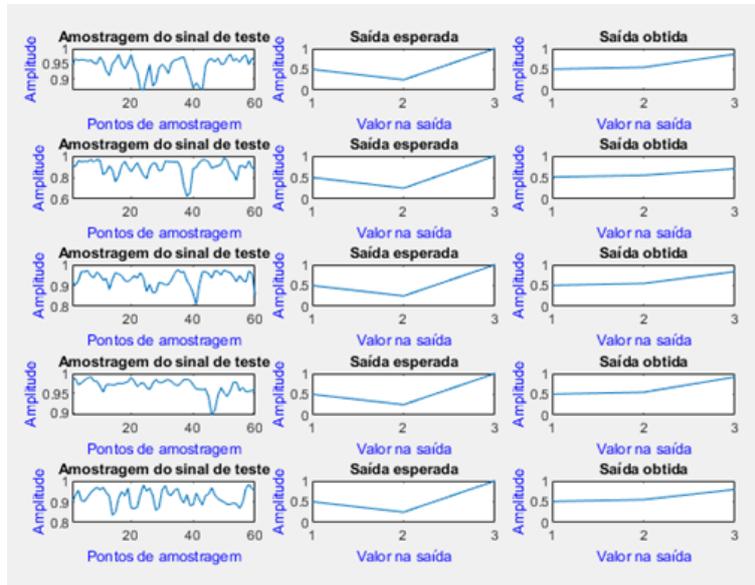
Figura 5.12: RNA-1: Amostras de validação (6 a 10).



Fonte: (Acervo do autor, 2025).

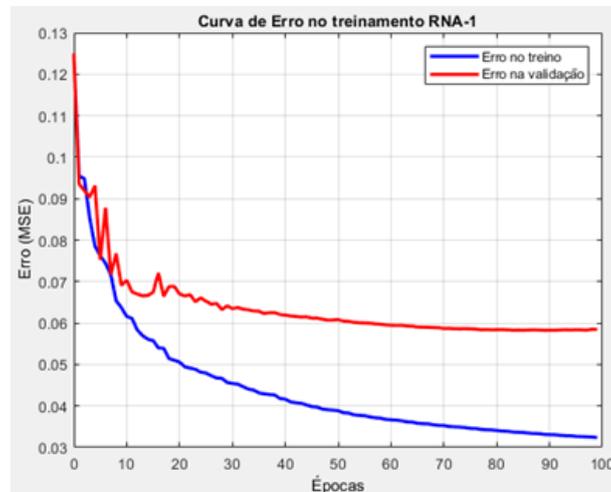
- A coluna **Perfil** identifica o perfil real do indivíduo testado;
- A coluna **Saída esperada** corresponde à identificação correta do indivíduo testado;
- A coluna **Saída obtida** corresponde à identificação obtida após teste do

Figura 5.13: RNA-1: Amostragens de validação (11 a 15).



Fonte: (Acervo do autor, 2025).

Figura 5.14: RNA-1: Curva de erro no treinamento e validação.

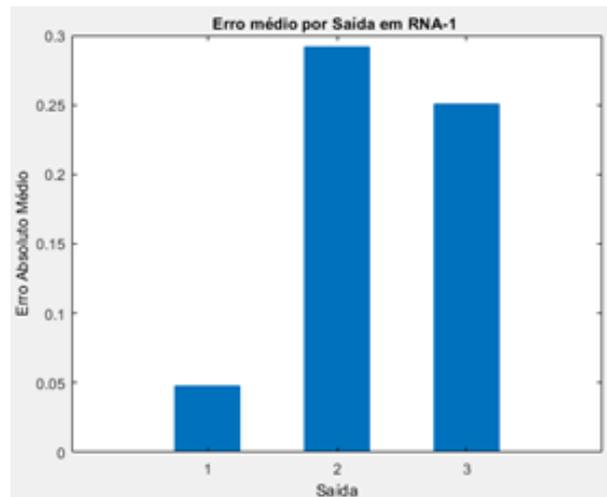


Fonte: (Acervo do autor,2025).

indivíduo;

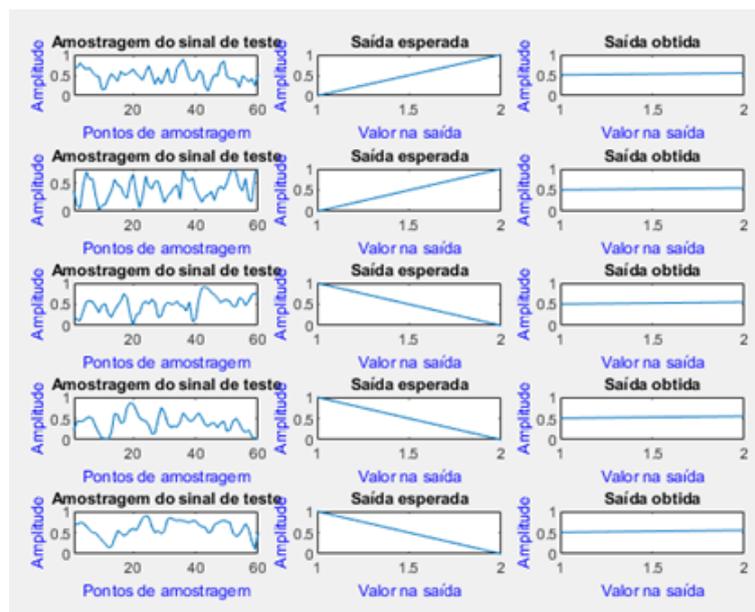
- A **coluna Análise** contém observações sobre o teste realizado com o indivíduo. Quando o teste acerta a identificação do perfil, esta coluna não é preenchida, na maioria das vezes (pra deixar a tabela mais compacta, visualmente), salvo quando necessário maior detalhamento, como ocorre no teste

Figura 5.15: RNA-1: Erro médio em cada neurônio da camada de saída.



Fonte: (Acervo do autor,2025).

Figura 5.16: RNA-2: Amostras de validação (1 a 5).



Fonte: (Acervo do autor,2025).

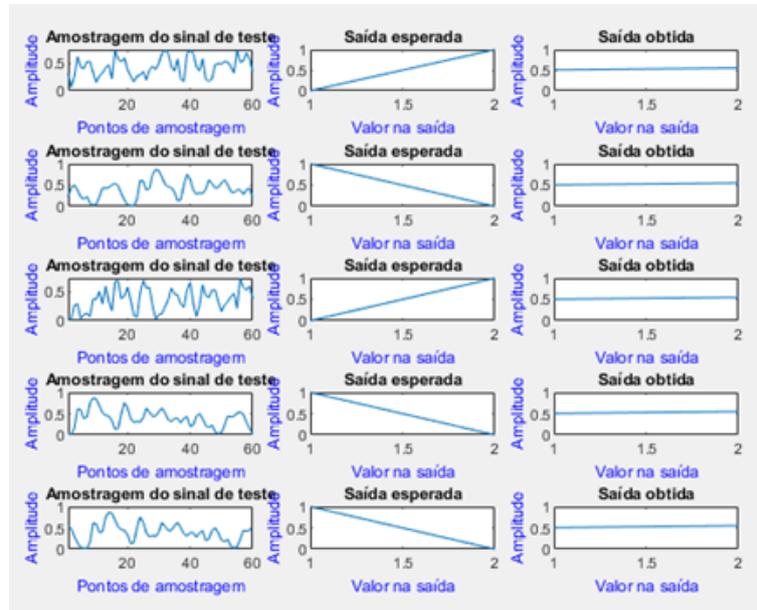
No. 11;

- A coluna **Conclusão** destaca o resultado do teste.

Comentários referentes aos testes da Tabela 5.1:

1. No teste No. 11, o indivíduo testado tem perfil FTD e foi identificado correta-

Figura 5.17: RNA-2: Amostras de validação (6 a 10).



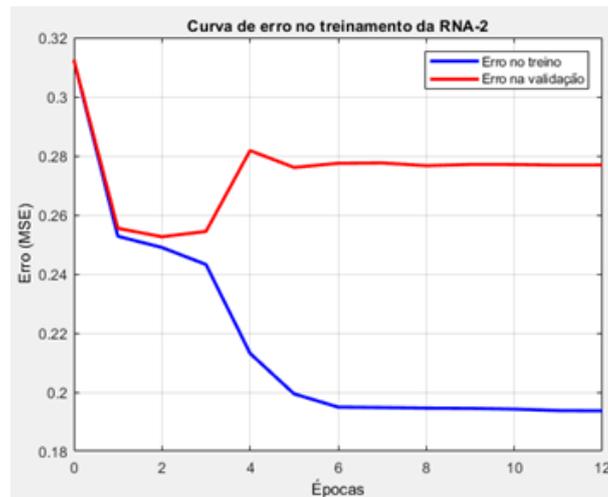
Fonte: (Acervo do autor, 2025).

No.	Perfil	Saída esperada	Saída obtida	Análise	Conclusão
1	AD	1	1		✓
2	HE	3	3		✓
3	AD	1	1		✓
4	HE	3	3		✓
5	HE	3	3		✓
6	HE	3	3		✓
7	HE	3	3		✓
8	HE	3	3		✓
9	HE	3	3		✓
10	HE	3	3		✓
11	FTD	2	2	[.5433 .5522 .5140]	✓
12	FTD	2	1	[.6661 .5547 .5005]	✗
13	AD	1	1		✓
14	AD	1	1		✓
15	HE	3	3		✓

Tabela 5.1: RNA-1: Análise da validação.

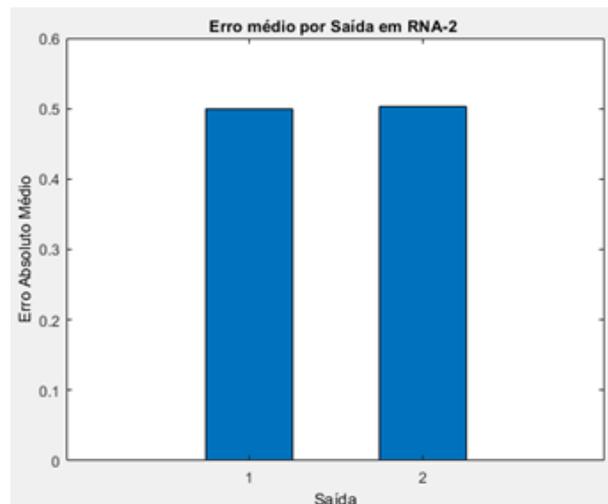
mente, como se destaca na coluna conclusão. Contudo, embora o teste tenha acertado, verifica-se que os neurônios da camada de saída possuem valores numéricos muito próximos, o que reflete um Grau de confiança baixo para a Saída número 2 da rede RNA-1. Isto pode ser contornado, através de rotinas de adaptação, a exemplo da implementada nesta rede. Destaque-se, ainda,

Figura 5.18: RNA-2: Curva de erro no treinamento e validação.



Fonte: (Acervo do autor,2025).

Figura 5.19: RNA-2: Erro médio em cada neurônio da camada de saída.



Fonte: (Acervo do autor,2025).

que esses resultados foram registrados após treinamento da rede com apenas 100 épocas, como mostra a Figura 5.14, o que sugere viabilidade de correção do problema através da redefinição dos parâmetros de inicialização da rede.

2. No teste No. 12, ocorre erro de identificação, com a mesma causa apresentada no item anterior.

Em conformidade com o estabelecido para a rede RNA-2, os eventos de validação

apresentados nas Figuras 5.16 e 5.17 são resumidos na Tabela 5.2.

No.	Perfil	Saída esperada	Saída obtida	Análise	Conclusão
1	AD23	2	2	[.5065 .5535]	✓
2	AD23	2	2	[.5068 .5503]	✓
3	AD1	1	2	[.5061 .5519]	✗
4	AD1	1	2	[.5061 .5520]	✗
5	AD1	1	2	[.5070 .5552]	✗
6	AD23	2	2	[.5061 .5521]	✓
7	AD1	1	2	[.5060 .5515]	✗
8	AD23	2	2	[.5055 .5498]	✓
9	AD1	1	2	[.5057 .5505]	✓
10	AD1	1	2	[.5065 .5534]	✗

Tabela 5.2: RNA-2: Análise da validação.

Comentários referentes aos testes da Tabela 5.2:

1. A análise dos valores numéricos da saída de RNA-2 indicam a necessidade de revisão do modelo. A diferença numérica muito pequena revela um nível de segurança muito baixo na discriminação entre os níveis inicial e intermediário-avanzado da doença de Alzheimer;
2. A diferenciação entre esses níveis através da rede RNA-2 não se mostrou viável pelo modelo, no primeiro momento. Contudo, após alterações na etapa de inicialização, alternativas de correção foram identificadas, a exemplo do aumento do número de épocas na etapa de treinamento.

5.7 Testes de RNA-1

A fase de testes constitui o estágio final do processo de modelagem e avaliação das redes neurais RNA-1 e RNA-2, sendo essencial para a verificação da capacidade de generalização dos modelos previamente treinados e validados. Diferentemente das fases anteriores, nesta etapa os parâmetros da rede permanecem inalterados, ou seja, não há atualização de pesos ou ajustes estruturais, exceto se a rotina de adaptação for habilitada. O objetivo é mensurar o desempenho real das redes diante de dados inéditos, simulando a aplicação em cenários clínicos reais.

As duas redes foram projetadas com finalidades distintas. A RNA-1, com arquitetura mapeando de $\mathbb{R}^{60} \rightarrow \mathbb{R}^3$, é responsável por classificar indivíduos nos perfis neurológicos: Doença de Alzheimer (AD), Demência Frontotemporal (FTD) e sujeitos neurologicamente saudáveis (HE). A RNA-2, que mapeia de $\mathbb{R}^{60} \rightarrow \mathbb{R}^2$, foi concebida para identificação dos estágios da Doença de Alzheimer, diferenciando os casos iniciais (AD1) dos estágios moderado e grave (AD23).

Os dados utilizados nesta fase são provenientes da mesma base de origem (Open-Neuro), porém representam conjuntos independentes daqueles utilizados para o treinamento e a validação, garantindo assim a imparcialidade da avaliação. Esses dados são submetidos ao mesmo processo de pré-processamento e extração de características (densidade espectral de potência e coerência entre os eletrodos T3 e T4, assegurando a uniformidade da análise. Nesta etapa, esse pré-processamento é executado no módulo Análise operação, apresentado na Figura 5.5.

A avaliação de desempenho das RNAs durante os testes é realizada por meio de métricas estatísticas consolidadas em problemas de classificação, tais como acurácia, sensibilidade, especificidade e precisão. Estas métricas permitem uma análise detalhada da performance das redes na distinção entre os perfis neurológicos e nos diferentes estágios da doença de Alzheimer (POWERS,2011).

É importante ressaltar que, nesta etapa, são observados especialmente os erros de classificação (falsos positivos e falsos negativos), pois esses impactam diretamente na viabilidade clínica da aplicação da rede. Além disso, os resultados obtidos nos testes subsidiam a tomada de decisão quanto à necessidade de refinamento da arquitetura da rede, ajustes nos critérios de pré-processamento ou redefinição do conjunto de características extraídas.

A etapa de testes valida a robustez dos modelos construídos e sua aplicabilidade prática, constituindo-se como um dos elementos mais críticos para a confiabilidade do sistema de diagnóstico assistido por redes neurais artificiais.

Referente à adaptação das redes, na fase de testes, ficou definido que:

- A rotina de adaptação é habilitada, toda vez que o grau de confiança de

qualquer uma das saídas da rede permanecer inferior a 50% por 20 avaliações consecutivas.

- Se a rotina de adaptação é habilitada, um ajuste parcial dos pesos é executado.

5.7.1 Seleção dos dados para teste de RNA-1

Os sinais para teste da RNA são obtidos da seguinte forma:

1. Um indivíduo da base de referência (OpenNeuro, Anexo A) é selecionado, aleatoriamente;
2. uma varredura do seu sinal de EEG nos pontos T3-T4 é realizada, de onde pacotes com 5 minutos de duração são extraídos;
3. Cada pacote é processado, através do Módulo Análise de operação (Figura 5.5), que obtém os padrões de coerência e densidade de potência, estratificados nas bandas delta δ e alfa α .
4. O conjunto inteiro dos padrões obtidos compõe o sinal de teste.
5. O sinal de teste é avaliado em cada janela de amostragem, sendo o resultado final aferido, conforme a moda identificada para todas as janelas, ou seja, o perfil com maior frequência.

Referente aos indivíduos selecionados para teste na base OpenNeuro (Anexo A), destaque-se:

- A quantidade de indivíduos selecionados aleatoriamente: 50.
- Identificação, conforme seu número de ordem: 1 a 36 - AD.
- Identificação, conforme seu número de ordem: 37 a 65 - HE.
- Identificação, conforme seu número de ordem: 66 a 88 - FTD.

Lista dos 50 indivíduos selecionados para teste com Perfil

No.	Ind	Perfil	No.	Ind	Perfil
1	27	AD	26	66	FTD
2	76	FTD	27	20	AD
3	79	FTD	28	55	HE
4	42	HE	29	58	HE
5	40	HE	30	13	AD
6	50	HE	31	53	HE
7	75	FTD	32	6	AD
8	25	AD	33	78	FTD
9	46	HE	34	8	HE
10	74	FTD	35	31	AD
11	85	FTD	36	52	HE
12	48	HE	37	49	HE
13	54	HE	38	88	FTD
14	43	HE	39	39	HE
15	82	FTD	40	33	AD
16	44	HE	41	83	FTD
17	45	HE	42	69	FTD
18	15	AD	43	68	FTD
19	59	HE	44	9	AD
20	34	AD	45	37	HE
21	1	AD	46	38	HE
22	77	FTD	47	81	FTD
23	65	HE	48	73	FTD
24	41	HE	49	17	AD
25	32	AD	50	35	AD

Tabela 5.3: Indivíduos selecionados para teste.

5.7.2 Testes realizados com RNA-1

As janelas gráficas de saída dos dois testes abaixo apresentados estão no Apêndice B. Elas mostram a resposta de saída do teste realizado com cada indivíduo, na mesma sequência em que estão listados na Tabela 5.3, em grupos de 10 a cada página.

1. Teste AD *Versus* Não AD

Este teste tem como objetivo identificar indivíduos com perfil AD. Ele contempla todos os indivíduos com esse perfil, listados na Tabela 5.3. O resultado está resumido na Tabela 5.4.

Ind	TESTE	RESULTADO	Ind	TESTE	RESULTADO
27	FTD	✗	6	AD	✓
25	AD	✓	8	FTD	✗
15	AD	✓	31	FTD	✗
34	AD	✓	33	AD	✓
1	AD	✓	9	AD	✓
32	AD	✓	17	AD	✓
20	AD	✓	35	AD	✓
13	AD	✓			

Tabela 5.4: Teste AD *versus* Não AD.

$$\text{SENSIBILIDADE: } S = \frac{VP}{VP + VN} = \frac{12}{12 + 3} = 80\% \quad (5.1)$$

$$\text{ESPECIFICIDADE: } E = \frac{VN}{VN + FP} = \frac{35}{35 + 2} = 94,59\% \quad (5.2)$$

$$\text{ACURACIA: } A = \frac{VP + VN}{NTD} = \frac{13 + 35}{50} = 94\% \quad (5.3)$$

Na Tabela 5.4, todos os indivíduos listados na coluna 'Ind' são aqueles da Tabela 5.3 com perfil AD. A coluna 'TESTE' apresenta a resposta obtida com o teste. A coluna 'RESULTADO' apresenta a avaliação final do teste realizado. Ela recebe

uma marca de conferência verde (✓), sinalizando que o resultado está certo; do contrário, recebe a marca X vermelha (✗), sinalizando que o resultado está errado. Sendo assim, verifica-se que o resultado dos testes foi errado para os indivíduos 27, 8 e 31 e foi certo, para todos os demais.

1. Teste HE *Versus* Não HE

Este teste tem como objetivo identificar indivíduos com perfil HE. Ele contempla todos os indivíduos com esse perfil, listados na Tabela 5.3. O resultado está resumido na Tabela 5.5.

Ind	TESTE	RESULTADO	Ind	TESTE	RESULTADO
42	HE	✓	65	HE	✓
40	HE	✓	41	HE	✓
50	FTD	✗	55	HE	✓
46	HE	✓	58	FTD	✗
48	HE	✓	53	HE	✓
54	HE	✓	52	HE	✓
43	HE	✓	49	HE	✓
44	FTD	✗	39	AD	✗
45	HE	✓	37	HE	✓
59	HE	✓	38	HE	✓

Tabela 5.5: Teste HE *versus* Não HE.

$$\text{SENSIBILIDADE: } S = \frac{VP}{VP + VN} = \frac{16}{16 + 4} = 80\% \quad (5.4)$$

$$\text{ESPECIFICIDADE: } E = \frac{VN}{VN + FP} = \frac{29}{29 + 1} = 96,66\% \quad (5.5)$$

$$\text{ACURACIA: } A = \frac{VP + VN}{NTD} = \frac{16 + 29}{50} = 70\% \quad (5.6)$$

Na Tabela 5.5, todos os indivíduos listados na coluna 'Ind' são aqueles da Tabela 5.3 com perfil HE. A coluna 'TESTE' apresenta a resposta obtida com o teste. A

coluna 'RESULTADO' apresenta a avaliação final do teste realizado. Ela recebe uma marca de conferência verde (✓), sinalizando que o resultado está certo; do contrário, recebe a marca X vermelha (✗), sinalizando que o resultado está errado. Sendo assim, verifica-se que o resultado dos testes foi errado para os indivíduos 50, 44, 58 e 39 e foi certo, para todos os demais.

Os resultados dos testes para identificação dos perfis AD e HE demonstram que a rede RNA-1 viabiliza a identificação de indivíduos portadores da doença de Alzheimer, inclusive no seu estágio inicial.

*"Ainda que eu falasse a língua dos
homens e dos anjos, sem Amor, eu
nada seria..."*

Apóstolo Paulo.

Coríntios, Capítulo 13, Versículo 1.

Capítulo 6

Discussão e Conclusões

No universo das patologias neurológicas, uma demência existe quando o cérebro é afetado causando problemas cognitivos. O diagnóstico desse tipo de problema é baseado em vários critérios, como estilo de vida, exames laboratoriais e de imagem, além de análise clínica em consultório. A Doença de Alzheimer, DA, compreende de 60 a 70% das demências que atingem os idosos (DURONGBHAN et al.,2019). Contudo, o seu diagnóstico na fase inicial da doença ainda é considerado muito difícil, uma vez que seus sintomas são confundidos com aqueles também desenvolvidos pelo processo natural de envelhecimento. Por este motivo, o desenvolvimento de marcadores capazes de diminuir essa dificuldade é de grande interesse público, sendo a motivação para pesquisas com esse propósito, tendo em vista a expectativa de envelhecimento da população mundial (BEVILACQUA et al.,2015; SOLANO-ROJAS; VILLALÓN-FONSECA; MARÍN-RAVENTÓS,2020). Neste trabalho, o sinal de EEG foi usado como origem de marcadores que possibilitam o desenvolvimento de ferramentas auxiliares no diagnóstico da doença de Alzheimer.

A base de dados usada no desenvolvimento deste trabalho está disponível na plataforma OpenNeuro (MULTIADOUS,2023). O teste foi aplicado em 50 indivíduos dessa base, por amostragem aleatória, conforme Seção 5.7.2.

Considerando a alta complexidade dos sinais de EEG, que apresenta padrões similares, mesmo quando o seu portador é submetido a diferentes excitações, verifica-se que o desenvolvimento de estratégias que aumentam o grau de discernimento

do estado neurológico desse portador é relevante. Nesse sentido, ferramentas usadas com esse objetivo, como a apresentada nesta tese, se complementam. Até o momento, isoladamente, nenhuma pode garantir definitivamente o diagnóstico neurológico. Contudo, servem como auxílio e orientação das equipes médicas indicando as próximas etapas a serem cumpridas para o alcance desse objetivo.

6.1 Discussão

Os resultados obtidos com o desenvolvimento desse sistema baseado em rede neural artificial (RNA) para a identificação de portadores da Doença de Alzheimer (DA) a partir de sinais de EEG demonstraram a relevância do modelo, principalmente por sua capacidade de classificação da doença de Alzheimer, inclusive no seu estágio inicial. A estratégia de modularidade aplicada ao seu desenvolvimento permitiu melhor acompanhamento da etapa de testes, viabilizando uma melhor conferência do fluxo de dados na rede. A estrutura modular desenvolvida permite não apenas a sua reutilização em parte ou integralmente, mas também a sua adaptação para outros contextos diagnósticos, após pequenos ajustes. Isso confere ao modelo uma flexibilidade para aplicações em outras doenças neurológicas e afins, ampliando sua viabilidade em diferentes cenários clínicos e de pesquisa.

Um dos aspectos essenciais para o desempenho de qualquer sistema baseado em redes neurais artificiais é a qualidade dos dados aplicados no seu treinamento. Assim, a etapa de processamento desses dados, viabilizando a extração de características relevantes a partir dos sinais de EEG é fundamental - Trata-se de um fator determinante para viabilizar qualquer RNA. Na RNA-1 implementada, é possível discriminar portadores da DA, diferenciando-os de outras doenças neurológicas e do grupo controle, composto por indivíduos saudáveis. Assim, a aplicação de técnicas de pré-processamento e extração de atributos desempenha um papel importante na etapa de treinamento e validação do modelo, permitindo que a RNA adquira a capacidade de generalização necessária para uma classificação eficiente.

O preparo dos dados considera técnicas como normalização, segmentação, rotação

e seleção de atributos mais relevantes. Esses procedimentos são essenciais para garantir a qualidade da entrada da RNA e minimizar interferências que possam comprometer o desempenho do sistema. Além disso, a validação cruzada e a divisão equilibrada entre conjuntos de treinamento e teste são aplicadas para assegurar a confiabilidade dos resultados obtidos.

A modularidade do sistema desenvolvido representa um diferencial significativo, permitindo sua reutilização, tanto parcial, através de um módulo com função específica, quanto integralmente, com pequenos ajustes para identificação de outras doenças neurológicas. Essa característica amplia o potencial de aplicação do modelo, consistindo numa ferramenta para diagnósticos baseados em EEG em um espectro mais amplo de doenças.

Em resumo, o processamento adequado dos dados e a arquitetura modular do sistema são elementos que aumentam sua eficiência e flexibilidade. Esses fatores o tornam uma alternativa para auxílio no processo diagnóstico da doença de Alzheimer, contribuindo para avanços no segmento de diagnóstico médico.

6.2 Conclusão

O diagnóstico da doença de Alzheimer (DA) tem evoluído significativamente ao longo das últimas décadas. Tradicionalmente, o diagnóstico é baseado em um conjunto de sinais clínicos, exames neuropsicológicos e, em alguns casos, exames de imagem, como a ressonância magnética (RM) e a tomografia por emissão de pósitrons (PET). No entanto, esses métodos podem ser caros, demorados e, muitas vezes, ineficazes em estágios iniciais da doença. Nesse contexto, a capacidade de diagnosticar a DA apenas por sinais de EEG representa um avanço significativo, oferecendo uma alternativa mais acessível, rápida e menos invasiva.

O EEG é uma técnica amplamente utilizada para avaliar a atividade elétrica do cérebro, que reflete a função neuronal. Em indivíduos com Alzheimer, alterações na atividade elétrica, como a diminuição das ondas alfa e o aumento das ondas teta e delta, podem ser observadas. Estudos recentes indicam que a análise detalhada

desses padrões de atividade cerebral pode identificar a doença de maneira precoce, com uma precisão crescente, à medida que as tecnologias de análise dos sinais se tornam mais sofisticadas, como o uso de técnicas de inteligência artificial para detectar padrões específicos de sinais de EEG (TZIMOURTA et al.,2019).

Uma das principais vantagens do EEG sobre os métodos tradicionais é seu baixo custo. O EEG é muito mais acessível em comparação com exames como a PET, que podem custar milhares de reais, ou a ressonância magnética funcional, que requer equipamento especializado e infraestrutura cara. Além disso, o EEG é portátil, o que possibilita seu uso em contextos clínicos mais simples, como em consultórios ou até mesmo em ambientes domiciliares, facilitando o monitoramento contínuo do paciente, especialmente em regiões com poucos recursos médicos (HUANG et al.,2008).

Além disso, o EEG é menos invasivo e mais rápido. Enquanto os exames de imagem podem levar mais tempo para serem realizados e requerem processos complexos, o EEG pode fornecer resultados quase imediatos, permitindo uma avaliação ágil do paciente. Isso é particularmente importante para pacientes idosos, que muitas vezes enfrentam dificuldades de deslocamento e longos períodos de espera para exames mais complexos.

Por fim, a capacidade de realizar um diagnóstico precoce da DA é essencial para o planejamento do tratamento e convívio com a doença, uma vez que ela ainda não tem cura. Quanto mais cedo a doença é identificada, maiores são as chances de intervir com terapias que podem retardar a progressão dos sintomas. Em comparação com os métodos convencionais, que também podem falhar em detectar a doença nas suas fases iniciais, o EEG representa uma ferramenta promissora e eficaz para identificar a doença de Alzheimer de forma mais ágil e acessível (AMIN-NAJI; MAHDAVINATAJ; AGHAGOLZADEH,2019).

Assim, o uso de EEG para diagnosticar Alzheimer traz benefícios significativos, incluindo redução de custos, maior acessibilidade, rapidez e a possibilidade de diagnóstico precoce, aspectos que tornam a técnica abordada neste trabalho uma

contribuição importante, uma vez que ela pode auxiliar os profissionais da área de saúde, principalmente em países com grande extensão territorial, onde a existência de municípios com difícil acesso e grande escassez de recursos é muito comum.

6.3 Trabalhos Futuros

Redes neurais artificiais (RNA) aplicadas à análise de EEG para o diagnóstico da doença de Alzheimer (DA) segue avançando e diversas possibilidades de desenvolvimento e ampliação dessa abordagem são identificáveis. A seguir, são apresentadas seis sugestões de trabalhos futuros que podem expandir e aplicar o mesmo sistema baseado em RNA, com poucas adaptações, em outros contextos:

- Detecção de outras doenças neurodegenerativas: a RNA treinada para identificar padrões de EEG na DA pode ser adaptada, com pequenas modificações, para detectar outras doenças neurodegenerativas, como a doença de Parkinson, esclerose múltipla ou demência frontotemporal. Muitas dessas condições também causam alterações no padrão elétrico cerebral, e a mesma rede neural poderia ser utilizada para identificar essas doenças, ampliando o espectro diagnóstico da técnica aplicada;
- Monitoramento de pacientes com distúrbios epilépticos: a epilepsia é outra condição que altera significativamente a atividade elétrica cerebral. A rede neural utilizada para a DA pode ser aplicada para identificar crises epilépticas ou padrões de atividade cerebral relacionados à epilepsia. A rede neural pode ser usada para monitorar pacientes em tempo real, ajudando na previsão de crises e no ajuste dos tratamentos de forma mais personalizada;
- Prevenção e identificação de pacientes com fatores de risco para doença de Alzheimer: a RNA pode ser aplicada para identificar alterações nos sinais de EEG em indivíduos com fatores de risco para o desenvolvimento de Alzheimer, como histórico familiar, diabetes tipo 2, hipertensão ou comprometimento cognitivo leve. O monitoramento precoce de padrões de EEG em grupos de risco

pode facilitar a intervenção precoce e estratégias preventivas, adiando o aparecimento dos primeiros sintomas clínicos da doença;

- Desenvolvimento de sistemas de diagnóstico remoto e telemedicina: a portabilidade do EEG e a eficácia da RNA no diagnóstico precoce da DA podem ser exploradas em sistemas de telemedicina. A rede neural pode ser aplicada em dispositivos de EEG portáteis, permitindo que pacientes em áreas remotas ou de difícil acesso enviem seus sinais de EEG para análise em tempo real por médicos ou sistemas automatizados, proporcionando diagnósticos rápidos e precisos sem a necessidade de deslocamento para centros especializados;
- Identificação de padrões de EEG em portadores da doença de Parkinson: a identificação de padrões de EEG em portadores de Parkinson pode ajudar no diagnóstico da doença, com benefício significativo nas situações em que o portador tem idade muito inferior à faixa etária onde a doença é prevalente. Este diagnóstico baseado em EEG pode adicionar segurança ao processo e permitir a adoção de terapias que contribuam, de forma mais efetiva, com o retardamento da progressão da doença. Isto por se tratar de uma doença rara em pacientes jovens, outros marcadores (a exemplo da redução da dopamina) são comumente negligenciados, até que apareçam os seus sintomas mais clássicos, como a rigidez muscular e lentidão nos movimentos;
- Identificação de padrões de resposta em sinais miográficos: o conhecimento dos padrões de resposta aos estímulos elétricos aplicados durante um exame de eletroneuromiografia serve como referência para o desenvolvimento de sistema para interpretação e geração automática de laudos desses exames.

Esses trabalhos podem ampliar significativamente a aplicação da RNA desenvolvida, não apenas no diagnóstico da doença de Alzheimer, mas também em outras condições neurológicas, contribuindo para a melhoria do cuidado e monitoramento de pacientes, além de promover a integração de novas tecnologias em sistemas de saúde.

6.4 Artigos Publicados em Periódicos e Conferências

Alves, G. J., Inocência, A. V. de M., Cunha, N. A., Alves, J. V. dos S., Araújo, R. E. de, Rodrigues, M. A. B. (2025). Method for recognizing EEG frequency patterns using artificial neural networks and signal processing. *Caderno Pedagógico*, 22(4), e14397. <https://doi.org/10.54033/cadpedv22n4-241>

Alves, G. J., Inocência, A. V. de M., Alves, J. V. dos S., Araújo, R. E. de, Rodrigues, M. A. B. (2024). Graphene: future prospects for biomedical engineering applications. *Caderno Pedagógico*, 21(10), e9945. <https://doi.org/10.54033/cadpedv21n10-407>

Cunha, N. A., Inocência, A. V. de M., Cavalcanti, E.L., Alves, G. J., da Silva, M.G.M.N., Silva, M.B.C, Rodrigues, M. A. B. (2024). Computer vision: applications in Biomedical Engineering. *Caderno Pedagógico*, 21(13), e11502. <https://doi.org/10.54033/cadpedv21n13-056>

Alves, G.J., Freitas, D.R., Inocência, A.V.M., Cavalcante, E.L., Rodrigues, M.A.B., de Araujo, R.E. (2022). A Dynamic Artificial Neural Network for EEG Patterns Recognition. In: Bastos-Filho, T.F., de Oliveira Caldeira, E.M., Frizera-Neto, A. (eds) XXVII Brazilian Congress on Biomedical Engineering. CBEB 2020. IFMBE Proceedings, vol 83. Springer, Cham. https://doi.org/10.1007/978-3-030-70601-2_281

Bispo, B.C., Cavalcante, E.L., Esteves, G.R.P., Silva, M.B.C., Alves, G.J., Rodrigues, M.A.B. (2022). Access Control in Hospitals with RFID and BLE Technologies. In: Bastos-Filho, T.F., de Oliveira Caldeira, E.M., Frizera-Neto, A. (eds) XXVII Brazilian Congress on Biomedical Engineering. CBEB 2020. IFMBE Proceedings, vol 83. Springer, Cham. https://doi.org/10.1007/978-3-030-70601-2_137

Referências

AGARAP, A. F. **Deep Learning using Rectified Linear Units (ReLU)**.

2018. Available at <https://arxiv.org/abs/1803.08375>.

AGNIHOTRI, A.; YADAV, V.; KAUSHIK, V. D. Role of data mining and machine learning techniques in medical imaging. **International Journal of Advanced Intelligence Paradigms**, Inderscience Publishers (IEL), v. 15, n. 3, p. 340–351, 2020.

AHMADLOU, M.; ADELI, H.; ADELI, A. Fractality and a wavelet-chaos-neural network methodology for eeg-based diagnosis of autistic spectrum disorder.

Journal of Clinical Neurophysiology, LWW, v. 27, n. 5, p. 328–333, 2010.

AKIN, M. Comparison of wavelet transform and fft methods in the analysis of eeg signals. **Journal of medical systems**, Springer, v. 26, p. 241–247, 2002.

AL-FAHOUM, A. S.; AL-FRAIHAT, A. A. Methods of eeg signal features extraction using linear analysis in frequency and time-frequency domains.

International Scholarly Research Notices, Wiley Online Library, v. 2014, n. 1, p. 730218, 2014.

AL-QAZZAZ, N. K.; ALI, S. H. B. M.; AHMAD, S. A.; CHELLAPPAN, K.; ISLAM, M. S.; ESCUDERO, J. Role of eeg as biomarker in the early detection and classification of dementia. **The Scientific World Journal**, Wiley Online Library, v. 2014, n. 1, p. 906038, 2014.

ALBERTS, B. **Biologia Molecular da Célula - Fluxo de Íons pela Membrana e Potencial de Ação**. 2010. Acessado em: 28 fev. 2025. Disponível em:

<https://neurocienciaspt.blogspot.com/2013/02/v-behaviorurldefaultvmlo.html>.

ALJOVIĆ, A.; BADNJEVIĆ, A.; GURBETA, L. Artificial neural networks in the discrimination of alzheimer's disease using biomarkers data. In: IEEE. **2016 5th Mediterranean Conference on Embedded Computing (MECO)**. [S.l.], 2016. p. 286–289.

ALTMAN, D. G.; BLAND, J. M. Diagnostic tests. 1: Sensitivity and specificity. **BMJ: British Medical Journal**, British Medical Journal, v. 308, n. 6943, p. 1552, 1994.

AMIN-NAJI, M.; MAHDAVINATAJ, H.; AGHAGOLZADEH, A. Alzheimer's disease diagnosis from structural mri using siamese convolutional neural network. In: **2019 4th International Conference on Pattern Recognition and Image Analysis (IPRIA)**. [S.l.: s.n.], 2019. p. 75–79.

ASSOCIATION, A. 2019 alzheimer's disease facts and figures. **Alzheimer's & dementia**, Wiley Online Library, v. 15, n. 3, p. 321–387, 2019.

BABILONI, C.; BLINOWSKA, K.; BONANNI, L. et al. What electrophysiology tells us about alzheimer's disease: a window into the synchronization and connectivity of brain neurons. **Neurobiology of Aging**, Elsevier, v. 85, p. 58–73, 2020.

BABILONI, C.; LIZIO, R.; MARZANO, N.; CAPOTOSTO, P.; SORICELLI, A.; TRIGGIANI, A. I.; CORDONE, S.; GESUALDO, L.; PERCIO, C. D. Brain neural synchronization and functional coupling in alzheimer's disease as revealed by resting state eeg rhythms. **International Journal of Psychophysiology**, Elsevier, v. 103, p. 88–102, 2016.

BABILONI, C.; ROSSINI, P. M.; BINETTI, G.; NOBILI, F. Eeg markers of alzheimer's disease: A combination of decreased alpha and increased theta rhythms. **Clinical Neurophysiology**, Elsevier, v. 117, n. 8, p. 1700–1708, 2006.

BAKER, M.; AKROFI, K.; SCHIFFER, R.; O'BOYLE, M. W. Eeg patterns in mild cognitive impairment (mci) patients. **The open neuroimaging journal**, v. 2, p. 52, 2008.

BARROS, A. de S.; CORDEIRO, K. N. de S.; CARVALHO, A. C. G. Alzheimer: Os desafios familiares frente a este diagnóstico. **Revista Interdisciplinar Pensamento Científico**, v. 5, n. 4, 2019.

BAŞAR, E.; BAŞAR-EROGLU, C.; KARAKAŞ, S.; SCHÜRMAN, M. Gamma, alpha, delta, and theta oscillations govern cognitive processes. **International journal of psychophysiology**, Elsevier, v. 39, n. 2-3, p. 241–248, 2001.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neuroscience: Exploring the Brain**. 4. ed. [S.l.]: Wolters Kluwer, 2015.

BERTÈ, F.; LAMPONI, G.; CALABRÒ, R. S.; BRAMANTI, P. Elman neural network for the early identification of cognitive impairment in alzheimer's disease. **Functional neurology**, v. 29, n. 1, p. 57, 2014.

BEVILACQUA, V.; SALATINO, A. A.; LEO, C. D.; TATTOLI, G.; BUONGIORNO, D.; SIGNORILE, D.; BABILONI, C.; PERCIO, C. D.; TRIGGIANI, A. I.; GESUALDO, L. Advanced classification of alzheimer's disease and healthy subjects based on eeg markers. In: IEEE. **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2015. p. 1–5.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer, 2006.

CALIL, V.; ELLIOTT, E.; BORELLI, W. V.; BARBOSA, B. J. A. P.; BRAM, J.; SILVA, F. d. O.; CARDOSO, L. G. M.; MARIANO, L. I.; DIAS, N.; HORNBERGER, M. et al. Challenges in the diagnosis of dementia: insights from the united kingdom-brazil dementia workshop. **Dementia & Neuropsychologia**, SciELO Brasil, v. 14, n. 03, p. 201–208, 2020.

CARROLL; DICKINSON. Construction of neural nets using the radon transform. In: IEEE. **International 1989 joint conference on neural networks**. [S.l.], 1989. p. 607–611.

CASSANI, R.; ESTARELLAS, M.; SAN-MARTIN, R.; FRAGA, F. J.; FALK, T. H. Systematic review on resting-state eeg for alzheimer's disease diagnosis and progression assessment. **Disease Markers**, Hindawi, v. 2018, p. 5174815, 2018.

CHATRIAN, G. E.; LETTICH, E.; NELSON, P. L. Ten percent electrode system for topographic studies of spontaneous and evoked eeg activities. **American Journal of EEG technology**, Taylor & Francis, v. 25, n. 2, p. 83–92, 1985.

CORRÊA, M. C. S. M. Anatomia e fisiologia. 2016.

CUESTA, P.; GARCÍA, M.; GRASA, E.; AL. et. Resting-state eeg power spectrum and functional connectivity in alzheimer's disease: A systematic review on cognitive and neuroimaging correlates. **Diagnostics**, MDPI, v. 11, n. 6, p. 1074, 2021.

CUN, Y. L.; DENKER, J.; SOLLA, S. Optimal brain damage, advances in neural information processing systems. **Optimal brain damage**. In **Advances in neural information processing systems**, p. 598–605, 1989.

CYBENKO, G. Correction:“approximation by superpositions of a sigmoidal function”,[math. control signal systems, 2.4 (1989), pp. 303-314]. **Math. Control Signal Systems**, v. 5, 1992.

DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. **IEEE Transactions on Information Theory**, IEEE, v. 36, n. 5, p. 961–1005, 1990.

_____. **Ten Lectures on Wavelets**. [S.l.]: SIAM, 1992.

DAUWELS, J.; VIALATTE, F.; CICHOCKI, A. Diagnosis of alzheimer’s disease from eeg signals: where are we standing? **Current Alzheimer Research**, Bentham Science Publishers direct, v. 7, n. 6, p. 487–505, 2010.

DEPOSITPHOTOS. **Imagens do Sistema Nervoso Humano**. 2025. Acessado em: 28 fev. 2025. Disponível em: [⟨https://depositphotos.com/br/photos/sistema-nervoso.html⟩](https://depositphotos.com/br/photos/sistema-nervoso.html).

DIBAL, J.; ODU, D.; VEMURI, S. Wavelet transform and applications to eeg analysis. **International Journal of Advanced Computer Science and Applications**, v. 10, n. 6, 2019.

DURONGBHAN, P.; ZHAO, Y.; CHEN, L.; ZIS, P.; MARCO, M. D.; UNWIN, Z. C.; VENNERI, A.; HE, X.; LI, S.; ZHAO, Y. et al. A dementia classification framework using frequency and time-frequency features based on eeg signals. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, IEEE, v. 27, n. 5, p. 826–835, 2019.

DYNAMICS.COM soft. **soft-dynamics.com**. 2023. Acessado em: 21 Set. 2023. Disponível em: [⟨Soft-dynamics.com⟩](https://soft-dynamics.com).

EIKELBOOM, W. S.; SINGLETON, E.; BERG, E. V. D.; COESMANS, M.; RASO, F. M.; BRUCHEM, R. L. V.; GOUDZWAARD, J. A.; JONG, F. J. D.; KOOPMANSCHAP, M.; HEIJER, T. D. et al. Early recognition and treatment of neuropsychiatric symptoms to improve quality of life in early alzheimer’s disease: Protocol of the beat-it study. **Alzheimer’s research & therapy**, Springer, v. 11, p. 1–12, 2019.

ELFWING, S.; UCHIBE, E.; DOYA, K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. **Neural Networks**, Elsevier, v. 107, p. 3–11, 2018.

ENGEL, A. K.; GERLOFF, C.; HILGETAG, C. C.; NOLTE, G. Intrinsic coupling modes: multiscale interactions in ongoing brain activity. **Neuron**, Elsevier, v. 80, n. 4, p. 867–886, 2013.

ESTATÍSTICA, I. B. de Geografia e. **Projeção da população do Brasil e das Unidades da Federação**. [S.l.]: IBGE Brasília, 2017.

FAUST, O.; ACHARYA, U. R.; ADELI, H.; ADELI, A. Wavelet-based eeg processing for computer-aided seizure detection and epilepsy diagnosis. **Seizure**, Elsevier, v. 26, p. 56–64, 2015.

FERENHOF, H. A.; FERNANDES, R. F. Desmistificando a revisão de literatura como base para redação científica: método sff. **Revista ACB: Biblioteconomia em Santa Catarina**, Associação Catarinense de Bibliotecários, v. 21, n. 3, p. 550–563, 2016.

FOUNDATION, E. **1st. trusted site for epilepsy and seizure news**. 2020. Acessado em: 21 Maio 2020. Disponível em: <https://www.epilepsy.com/>.

FOX, N. C.; COUSENS, S.; SCAHILL, R.; HARVEY, R. J.; ROSSOR, M. N. Using serial registered brain magnetic resonance imaging to measure disease progression in alzheimer disease: power calculations and estimates of sample size to detect treatment effects. **Archives of neurology**, American Medical Association, v. 57, n. 3, p. 339–344, 2000.

FREITAS, D. R. R. d. Plataforma para análise do sinal de eeg aplicado ao erd/ers no reconhecimento em tempo real da imaginação do movimento. **Universidade Federal de Pernambuco: Tese de doutorado**, 2017.

GALLANT. There exists a neural network that does not make avoidable mistakes. In: IEEE. **IEEE 1988 International Conference on Neural Networks**. [S.l.], 1988. p. 657–664.

GARSON, G. D. **Neural networks: An introductory guide for social scientists**. Sage, 1998.

GILI, T.; CERCIGNANI, M.; SERRA, L.; PERRI, R.; GIOVE, F.; MARAVIGLIA, B.; CALTAGIRONE, C.; BOZZALI, M. Regional brain atrophy and functional disconnection across alzheimer’s disease evolution. **Journal of Neurology, Neurosurgery & Psychiatry**, BMJ Publishing Group Ltd, v. 82, n. 1, p. 58–66, 2011.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: **Proceedings of the Thirteenth**

International Conference on Artificial Intelligence and Statistics (AISTATS). [S.l.]: PMLR, 2010. p. 249–256.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: **Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics (AISTATS)**. [S.l.]: PMLR, 2011. p. 315–323.

GOMES, M. A. C. **O papel dos biomarcadores na doença de Alzheimer**. Dissertação (Mestrado) — Universidade do Algarve (Portugal), 2015.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <https://www.deeplearningbook.org/>.

GORJI, H.; HADDADNIA, J. A novel method for early diagnosis of alzheimer’s disease based on pseudo zernike moment from structural mri. **Neuroscience**, Elsevier, v. 305, p. 361–371, 2015.

GROSSI, E.; MASSINI, G.; BUSCEMA, M.; SAVARÈ, R.; MAURELLI, G. Two different alzheimer diseases in men and women: clues from advanced neural networks and artificial intelligence. **Gender medicine**, Elsevier, v. 2, n. 2, p. 106–117, 2005.

GUPTA, M.; JIN, L.; HOMMA, N. **Static and dynamic neural networks: from fundamentals to advanced theory**. [S.l.]: John Wiley & Sons, 2004.

GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. **Journal of machine learning research**, v. 3, p. 1157–1182, 2003.

HAMPEL, H.; FRANK, R.; BROICH, K.; TEIPEL, S. J.; KATZ, R. G.; HARDY, J.; HERHOLZ, K.; BOKDE, A. L.; JESSEN, F.; HOESSLER, Y. C. et al. Biomarkers for alzheimer’s disease: academic, industry and regulatory perspectives. **Nature reviews Drug discovery**, Nature Publishing Group UK London, v. 9, n. 7, p. 560–574, 2010.

HAMPEL, H.; LISTA, S.; TEIPEL, S. J.; GARACI, F.; NISTICO, R.; BLENNOW, K.; ZETTERBERG, H.; BERTRAM, L.; DUYCKAERTS, C.; BAKARDJIAN, H. et al. Perspective on future role of biological markers in clinical therapy trials of alzheimer’s disease: a long-range point of view beyond 2020. **Biochemical pharmacology**, Elsevier, v. 88, n. 4, p. 426–449, 2014.

HASSIBI, B.; STORK, D. Second order derivatives for network pruning: Optimal brain surgeon. **Advances in neural information processing systems**, v. 5, 1992.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2nd. ed. Springer, 2009. Disponível em:

<https://web.stanford.edu/~hastie/ElemStatLearn/>.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. [S.l.]: Bookman Editora, 2001.

HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. In: **Proceedings of the IEEE First International Conference on Neural Networks**. [S.l.: s.n.], 1987. v. 3, p. 11–14.

_____. Theory of the backpropagation neural network. In: **Neural networks for perception**. [S.l.]: Elsevier, 1992. p. 65–93.

HUANG, C.; YAN, B.; JIANG, H.; WANG, D. Combining voxel-based morphometry with artificial neural network theory in the application research of diagnosing alzheimer's disease. In: **IEEE. 2008 International Conference on BioMedical Engineering and Informatics**. [S.l.], 2008. v. 1, p. 250–254.

HUANG, G.-B. Learning capability and storage capacity of two-hidden-layer feedforward networks. **IEEE transactions on neural networks**, IEEE, v. 14, n. 2, p. 274–281, 2003.

ISLAM, J.; ZHANG, Y. Early diagnosis of alzheimer's disease: A neuroimaging study with deep learning architectures. In: **Proceedings of the IEEE conference on computer vision and pattern recognition workshops**. [S.l.: s.n.], 2018. p. 1881–1883.

JELLES, B.; SCHELTENS, P.; FLIER, W. Van der; JONKMAN, E.; SILVA, F. L. da; STAM, C. J. Global dynamical analysis of the eeg in alzheimer's disease: frequency-specific changes of functional interactions. **Clinical neurophysiology**, Elsevier, v. 119, n. 4, p. 837–841, 2008.

JEONG, J. Eeg dynamics in patients with alzheimer's disease. **Clinical Neurophysiology**, Elsevier, v. 115, n. 7, p. 1490–1505, 2004.

JIANG, M.; LIU, X.; ZHANG, Z. et al. A review of deep learning approaches for the analysis of medical imaging data in alzheimer's disease. **Artificial Intelligence in Medicine**, Elsevier, v. 124, p. 102105, 2022.

JOHNSON A., P. T. . M. R. Ten percent electrode system for topographic studies of spontaneous and evoked eeg activities. **PhysioNet**, 2016.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015.

JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. **Neuroimage**, Elsevier, v. 34, n. 4, p. 1600–1611, 2007.

KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 5. ed. [S.l.]: McGraw-Hill, 2013.

KANELLOPOULOS, I.; WILKINSON, G. G. Strategies and best practice for neural network image classification. **International Journal of Remote Sensing**, Taylor & Francis, v. 18, n. 4, p. 711–725, 1997.

KARLIK, B.; OLGAC, A. V. Performance analysis of various activation functions in generalized mlp architectures of neural networks. **International Journal of Artificial Intelligence and Expert Systems**, v. 1, n. 4, p. 111–122, 2011.

KAVZOGLU, T.; MATHER, P. M. Pruning artificial neural networks: an example using land cover classification of multi-sensor images. **International Journal of Remote Sensing**, Taylor & Francis, v. 20, n. 14, p. 2787–2803, 1999.

KEIL, A.; MÜLLER, M. M.; GRUBER, T.; WIENBRUCH, C.; ELBERT, T. Human large-scale oscillatory brain activity during an operant shaping procedure. **Cognitive Brain Research**, Elsevier, v. 12, n. 3, p. 397–407, 2001.

KITCHENHAM, B. Procedures for performing systematic reviews. **Keele, UK, Keele University**, Citeseer, v. 33, n. 2004, p. 1–26, 2004.

KITCHENHAM, B.; PRETORIUS, R.; BUDGEN, D.; BRERETON, O. P.; TURNER, M.; NIAZI, M.; LINKMAN, S. Systematic literature reviews in software engineering—a tertiary study. **Information and software technology**, Elsevier, v. 52, n. 8, p. 792–805, 2010.

KRAMER, M. The power spectrum (part 1). In: _____. **Case Studies in Neural Data Analysis**. [s.n.], 2021. Disponível em: [⟨https://mark-kramer.github.io/Case-Studies-Python/03.html⟩](https://mark-kramer.github.io/Case-Studies-Python/03.html).

KRKOVÁ, V. Kolmogorov's theorem and multilayer neural networks. **Neural networks**, Elsevier, v. 5, n. 3, p. 501–506, 1992.

KUMRAL, D.; ŞAHIN, K. et al. Eeg-based functional connectivity analysis in alzheimer's disease: An integrative approach with clinical and neuroimaging data. **NeuroImage: Clinical**, Elsevier, v. 32, p. 102841, 2021.

- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LECUN, Y.; BOTTOU, L.; ORR, G. B.; MÜLLER, K.-R. Efficient backprop. **Neural Networks: Tricks of the Trade**, Springer, p. 9–50, 1998.
- LIVINGSTON, G.; HUNTLEY, J.; SOMMERLAD, A.; AMES, D.; BALLARD, C.; BANERJEE, S. et al. Dementia prevention, intervention, and care: 2020 report of the lancet commission. **The Lancet**, Elsevier, v. 396, n. 10248, p. 413–446, 2020.
- LOTTE, F.; CONGEDO, M.; LÉCUYER, A.; LAMARCHE, F.; ARNALDI, B. A review of classification algorithms for eeg-based brain–computer interfaces. **Journal of neural engineering**, IOP Publishing, v. 4, n. 2, p. R1, 2007.
- MA, C.-C.; LIU, A.-J.; LIU, A.-H.; ZHOU, X.-Y.; ZHOU, S.-N. Electroencephalogram global field synchronization analysis: a new method for assessing the progress of cognitive decline in alzheimer’s disease. **Clinical EEG and Neuroscience**, SAGE Publications Sage CA: Los Angeles, CA, v. 45, n. 2, p. 98–103, 2014.
- MAHMOOD, R.; GHIMIRE, B. Automatic detection and classification of alzheimer’s disease from mri scans using principal component analysis and artificial neural networks. In: IEEE. **2013 20th International conference on systems, signals and image processing (IWSSIP)**. [S.l.], 2013. p. 133–137.
- MANTRI, S.; PATIL, D.; AGRAWAL, P.; WADHAI, V. Non invasive eeg signal processing framework for real time depression analysis. In: IEEE. **2015 SAI intelligent systems conference (IntelliSys)**. [S.l.], 2015. p. 518–521.
- MARIANO, A. M.; ROCHA, M. S. Revisão da literatura: apresentação de uma abordagem integradora. In: **AEDEM International Conference**. [S.l.: s.n.], 2017. v. 18, p. 427–442.
- MATHWORKS, I. T. **Magnitude-Squared Coherence**. [S.l.], 2023. Disponível em: <https://www.mathworks.com/help/signal/ref/mscohere.html>.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943.
- MILTIADOUS, A. **A dataset of EEG recordings from: Alzheimer’s disease, Frontotemporal dementia and Healthy subjects**. 2023. Acessado em: 18 Feb 2023. Disponível em: <https://openneuro.org/datasets/ds004504/versions/1.0.5>.

- MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J. **Wavelet Toolbox User's Guide**. [S.l.], 2020.
- MORETTI, D. V. Eeg connectivity in alzheimer's disease: a resting state investigation. **Clinical Neurophysiology**, Elsevier, v. 139, p. 22–30, 2022.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. **Proceedings of the 27th International Conference on Machine Learning (ICML-10)**, p. 807–814, 2010.
- NIEDERMEYER, E.; SILVA, F. H. Lopes da. **Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. 6. ed. [S.l.]: Oxford University Press, 2010.
- _____. _____. 6. ed. New York: Oxford University Press, 2011.
- NIELSEN, M. A. **Neural Networks and Deep Learning**. Determination Press, 2015. Disponível em: <http://neuralnetworksanddeeplearning.com/>.
- NITRINI, R.; CARAMELLI, P.; BOTTINO, C. M. d. C.; DAMASCENO, B. P.; BRUCKI, S. M. D.; ANGHINAH, R. Diagnóstico da Doença de Alzheimer no Brasil: avaliação cognitiva e funcional. recomendações do departamento científico de neurologia cognitiva e do envelhecimento da academia brasileira de neurologia. **Arquivos de Neuro-psiquiatria**, SciELO Brasil, v. 63, p. 720–727, 2005.
- NITZSCHE, B. O.; MORAES, H. P. de; JÚNIOR, A. R. T. Doença de Alzheimer: novas diretrizes para o diagnóstico. **Rev Med Minas Gerais**, v. 25, n. 2, p. 237–243, 2015.
- NUNEZ, P. L.; SRINIVASAN, R. **Electric Fields of the Brain: The Neurophysics of EEG**. [S.l.]: Cambridge University Press, 2006.
- NWANKPA, C.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. **Activation Functions: Comparison of trends in Practice and Research for Deep Learning**. 2018. Available at <https://arxiv.org/abs/1811.03378>.
- OKOLI, C.; SCHABRAM, K. A guide to conducting a systematic literature review of information systems research. Ssrn, 2015.
- PANCHAL, F. S.; PANCHAL, M. Review on methods of selecting number of hidden nodes in artificial neural network. **International Journal of Computer Science and Mobile Computing**, v. 3, n. 11, p. 455–464, 2014.

- PEREIRA, L. T.; RICARDO, S. A evolução da análise de sinais biomédicos no auxílio ao diagnóstico clínico. **História da Ciência e Ensino: construindo interfaces**, v. 20, p. 28–38, 2019.
- PETROSIAN, A.; PROKHOROV, D.; LAJARA-NANSON, W.; SCHIFFER, R. Recurrent neural network-based approach for early recognition of alzheimer's disease in eeg. **Clinical Neurophysiology**, Elsevier, v. 112, n. 8, p. 1378–1387, 2001.
- PICKLE, N. T.; SHEARIN, S. M.; FEY, N. P. Dynamic neural network approach to targeted balance assessment of individuals with and without neurological disease during non-steady-state locomotion. **Journal of neuroengineering and rehabilitation**, Springer, v. 16, p. 1–9, 2019.
- POWERS, D. M. W. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. **Journal of Machine Learning Technologies**, v. 2, n. 1, p. 37–63, 2011.
- PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. **Neural and Adaptive Systems: Fundamentals Through Simulations**. [S.l.]: Wiley, 2000.
- RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. **Searching for Activation Functions**. 2017. Available at <https://arxiv.org/abs/1710.05941>.
- RASMUSSEN, J.; LANGERMAN, H. Alzheimer's disease—why we need early diagnosis. **Degenerative neurological and neuromuscular disease**, Taylor & Francis, p. 123–130, 2019.
- RIPLEY, B. D. Neural networks and related methods for classification. **Journal of the Royal Statistical Society: Series B (Methodological)**, Wiley Online Library, v. 56, n. 3, p. 409–437, 1994.
- RODRIGUES, M. A. B. et al. Sistema para detecção e classificação automática de apnéias do sono a partir de registros polissonográficos. Florianópolis, SC, 2002.
- RODRIGUES, T. de Q.; CASTRO, A. d. S. de; CONCEIÇÃO, T. F. da; LEITE, J. G. A. M.; FERREIRA, V. H. S.; FAUSTINO, A. M. F. Impacto da doença de alzheimer na qualidade de vida de pessoas idosas: revisão de literatura. **Revista Eletrônica Acervo Saúde**, v. 12, n. 4, p. e2833–e2833, 2020.
- RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. [S.l.]: pearson, 2016.

- SANDMANN, M. C.; PIANA, E. R.; SOUSA, D. S.; BITTENCOURT, P. R. de. Eletrencefalograma digital com mapeamento em demência de Alzheimer e doença de Parkinson: estudo prospectivo controlado. **Arquivos de Neuro-Psiquiatria**, SciELO Brasil, v. 54, p. 50–56, 1996.
- SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. [S.l.]: John Wiley & Sons, 2007.
- SCHAUF, C. L.; MOFFETT, D. F.; MOFFETT, S. B. Fisiologia humana. 1993.
- SHAH, A. K.; MITTAL, S. Invasive electroencephalography monitoring: Indications and presurgical planning. **Annals of Indian Academy of Neurology**, Medknow, v. 17, n. Suppl 1, p. S89–S94, 2014.
- SHAHRIARI, B.; SWERSKY, K.; WANG, Z.; ADAMS, R. P.; FREITAS, N. D. Taking the human out of the loop: A review of bayesian optimization. **Proceedings of the IEEE**, IEEE, v. 104, n. 1, p. 148–175, 2016.
- SHARMA, S.; SHARMA, S.; ATHAIYA, A. Activation functions in neural networks. **Towards Data Sci**, v. 6, n. 12, p. 310–316, 2017.
- SILVA, F. L. da. Eeg and meg: relevance to neuroscience. **Neuron**, Elsevier, v. 80, n. 5, p. 1112–1128, 2013.
- SILVA, I. S. d. S. et al. Circuitos mistos reconfiguráveis aplicados à medição de sinais biomédicos: rejeição de interferência de modo comum. Universidade Federal de Campina Grande, 2003.
- SILVERTHORN, D. U. **Fisiologia humana: uma abordagem integrada**. [S.l.]: Artmed editora, 2017.
- SMAILOVIC, U.; JELIC, V. Neurophysiological markers of alzheimer’s disease: Quantitative eeg approach. **Neurology and Therapy**, Springer, v. 8, n. 2, p. 37–55, 2019.
- SOLANO-ROJAS, B.; VILLALÓN-FONSECA, R.; MARÍN-RAVENTÓS, G. Alzheimer’s disease early detection using a low cost three-dimensional densenet-121 architecture. In: SPRINGER. **The Impact of Digital Technologies on Public Health in Developed and Developing Countries: 18th International Conference, ICOST 2020, Hammamet, Tunisia, June 24–26, 2020, Proceedings 18**. [S.l.], 2020. p. 3–15.
- SOUZA, B. L. C. d. Identificação de estado de fadiga com base em sinais de eletroencefalograma. Vitória, 2023.

SOUZA, L. C. d.; SARAZIN, M.; JÚNIOR, A. L. T.; CARAMELLI, P.; SANTOS, A. E. d.; DUBOIS, B. Biomarcadores da doença de alzheimer. **Arquivos de Neuro-Psiquiatria**, SciELO Brasil, v. 72, p. 227–231, 2014.

STAM, C.; NOLTE, G.; DAFFERTSHOFER, A. Phase lag index: Assessment of functional connectivity from multichannel eeg and meg with diminished bias from common sources. **Human Brain Mapping**, Wiley Online Library, v. 28, n. 11, p. 1178–1193, 2007.

STATHAKIS, D. How many hidden layers and nodes? **International Journal of Remote Sensing**, Taylor & Francis, v. 30, n. 8, p. 2133–2147, 2009.

SUBASI, A. Eeg signal classification using wavelet feature extraction and a mixture of expert model. **Expert Systems with Applications**, Elsevier, v. 32, n. 4, p. 1084–1093, 2007.

SUZUKI, K. **Artificial neural networks: methodological advances and biomedical applications**. [S.l.]: BoD–Books on Demand, 2011.

TEIXEIRA, J. B.; SOUZA, P. R. B. d.; HIGA, J.; THEME, M. M. Mortality from alzheimer’s disease in brazil, 2000-2009. **Cadernos de saude publica**, SciELO Brasil, v. 31, n. 4, p. 850–860, 2015.

TEPLAN, M. Fundamentals of eeg measurement. **Measurement science review**, v. 2, n. 2, p. 1–11, 2002.

TREFETHEN, L. N. **Approximation theory and approximation practice, extended edition**. [S.l.]: SIAM, 2019.

TRUZZI, A.; LAKS, J. Doença de alzheimer esporádica de início precoce. **Archives of Clinical Psychiatry (São Paulo)**, SciELO Brasil, v. 32, p. 43–46, 2005.

TSOI, K. K.; CHAN, J. Y.; HIRAI, H. W.; WONG, S. Y.; KWOK, T. C. Cognitive tests to detect dementia: a systematic review and meta-analysis. **JAMA internal medicine**, American Medical Association, v. 175, n. 9, p. 1450–1458, 2015.

TZIMOURTA, K. D.; AFRANTOU, T.; IOANNIDIS, P.; KARATZIKOU, M.; TZALLAS, A. T.; GIANNAKEAS, N.; ASTRAKAS, L. G.; ANGELIDIS, P.; GLAVAS, E.; GRIGORIADIS, N. et al. Analysis of electroencephalographic signals complexity regarding alzheimer’s disease. **Computers & Electrical Engineering**, Elsevier, v. 76, p. 198–212, 2019.

UMICH. 10-20_ssystem_positioning.2020.Acessadoem : 21Set.2020.Disponível em : [ij](#).

VILLIERS, J. D.; BARNARD, E. Backpropagation neural nets with one and two hidden layers. **IEEE transactions on neural networks**, IEEE, v. 4, n. 1, p. 136–141, 1993.

WANG, F. The use of artificial neural networks in a geographical information system for agricultural land-suitability assessment. **Environment and planning A**, SAGE Publications Sage UK: London, England, v. 26, n. 2, p. 265–284, 1994.

WEEBLY. **Origin of Biopotentials**. 2024. Acessado em: 28 Dez. 2024. Disponível em: https://bmepedia.weebly.com/uploads/2/6/6/8/26683759/origin_of_biopotentials.pdf.

YAO, X. A review of evolutionary artificial neural networks. **International journal of intelligent systems**, Wiley Online Library, v. 8, n. 4, p. 539–567, 1993.

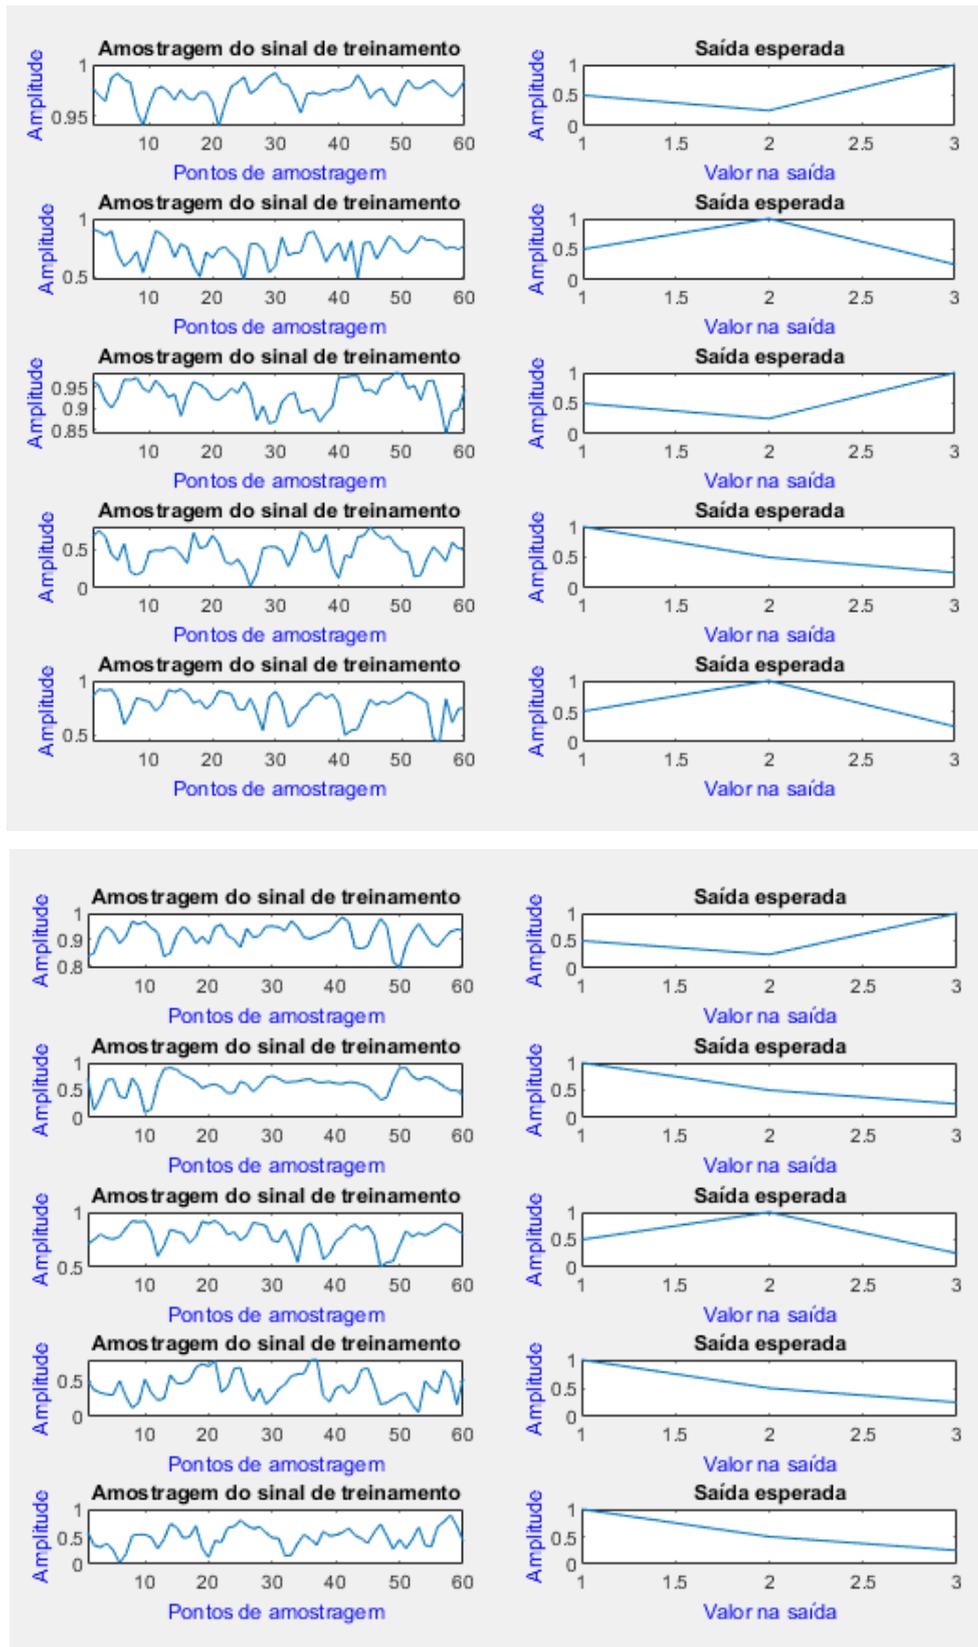
Apêndice A

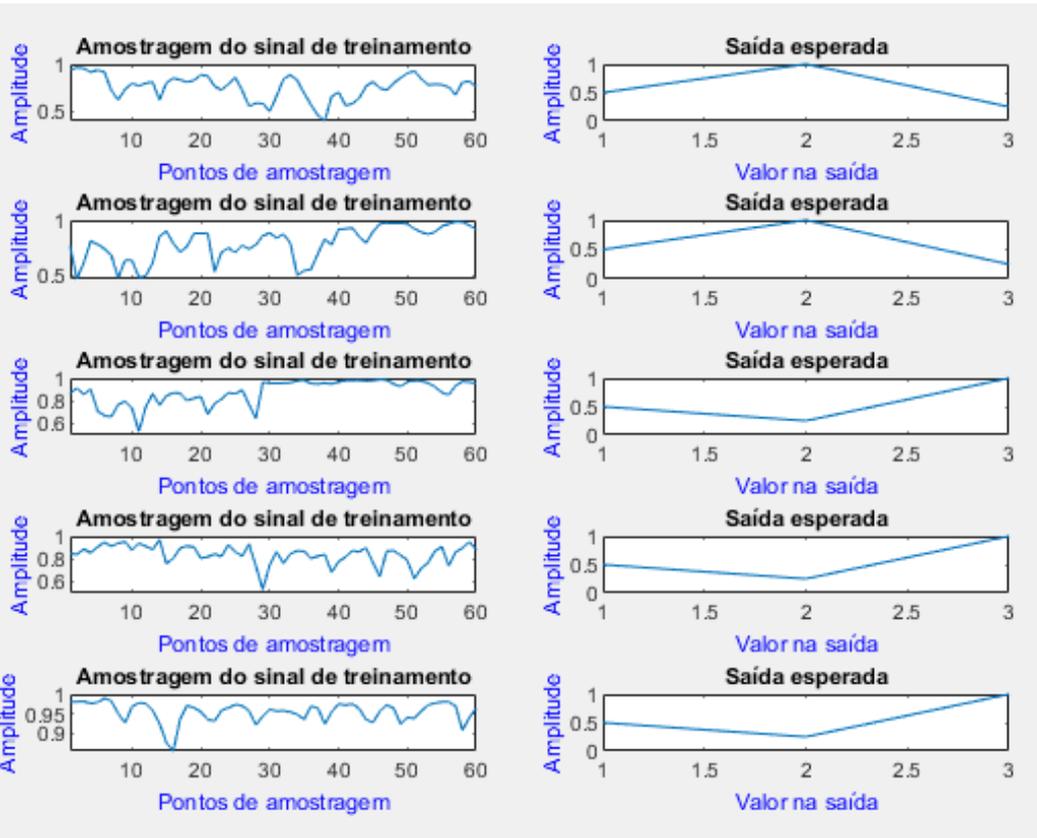
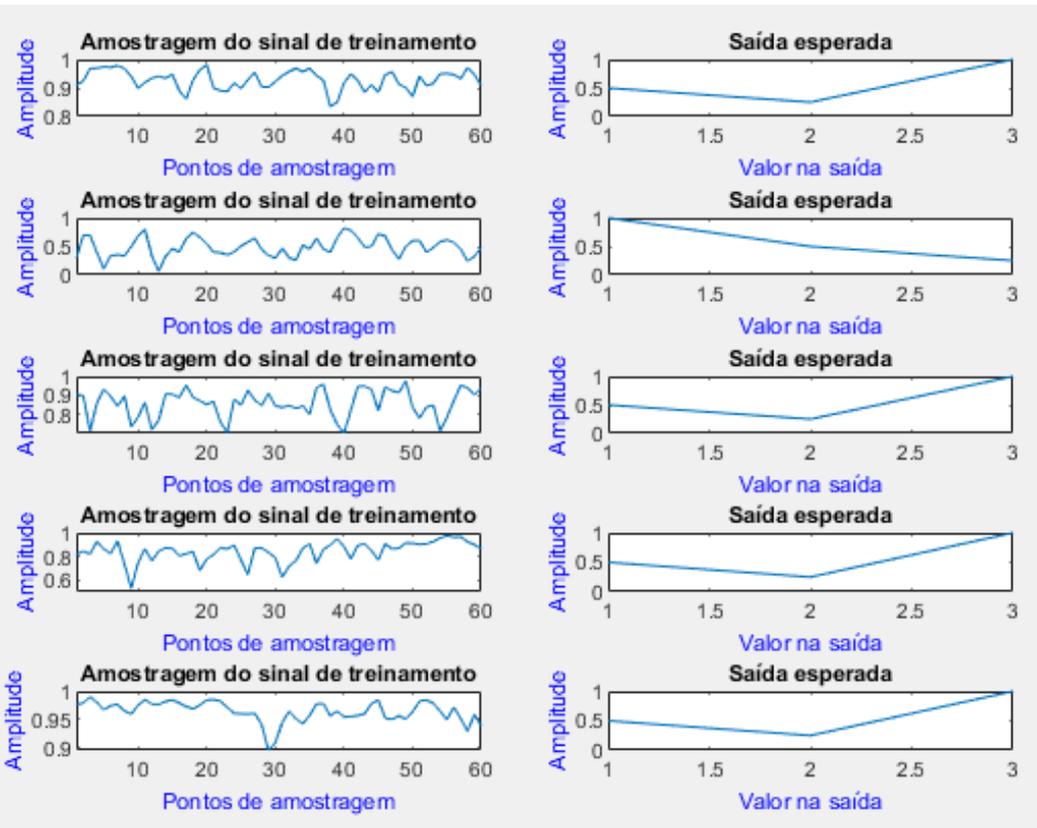
Amostragens do Treinamento e Validação

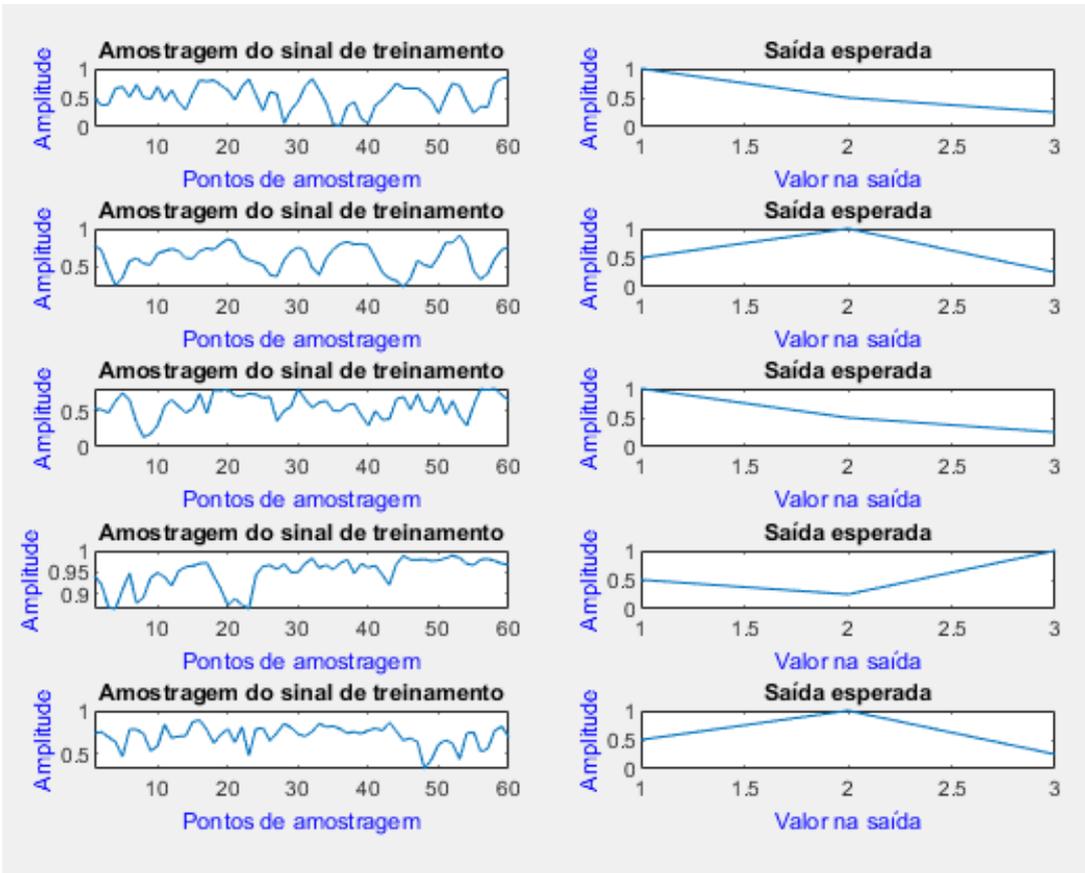
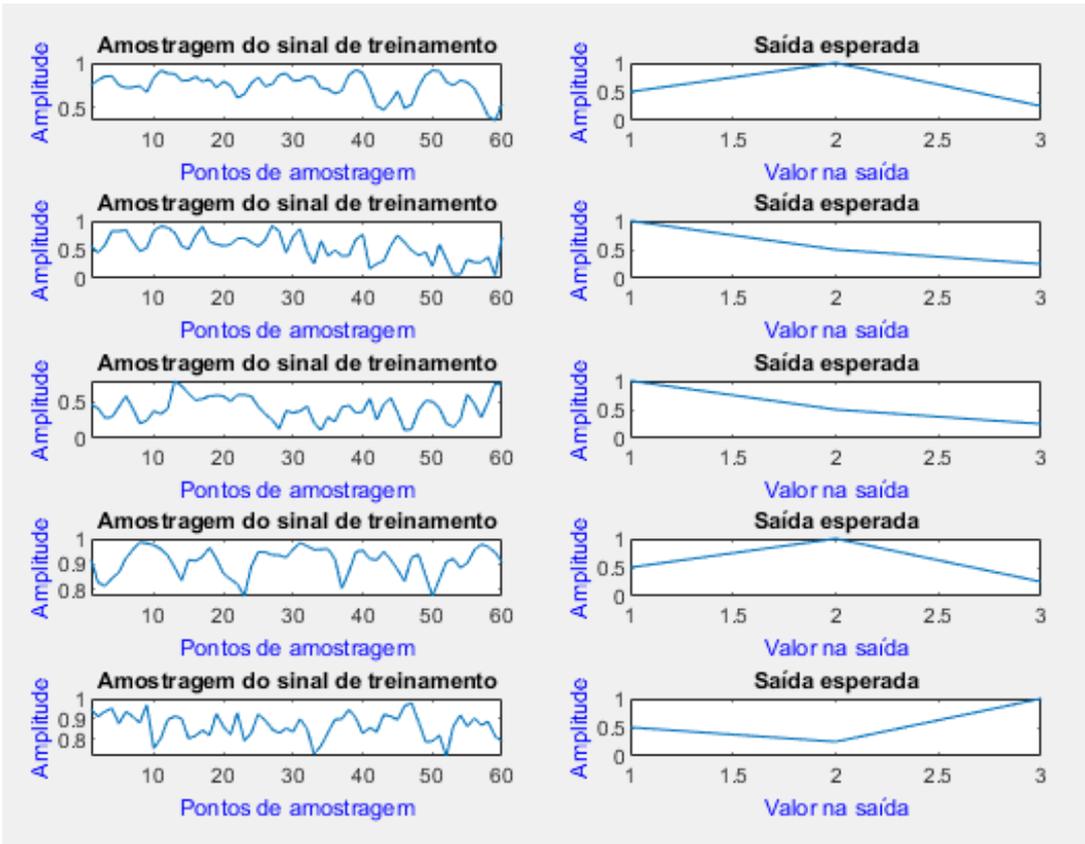
APÊNDICE A

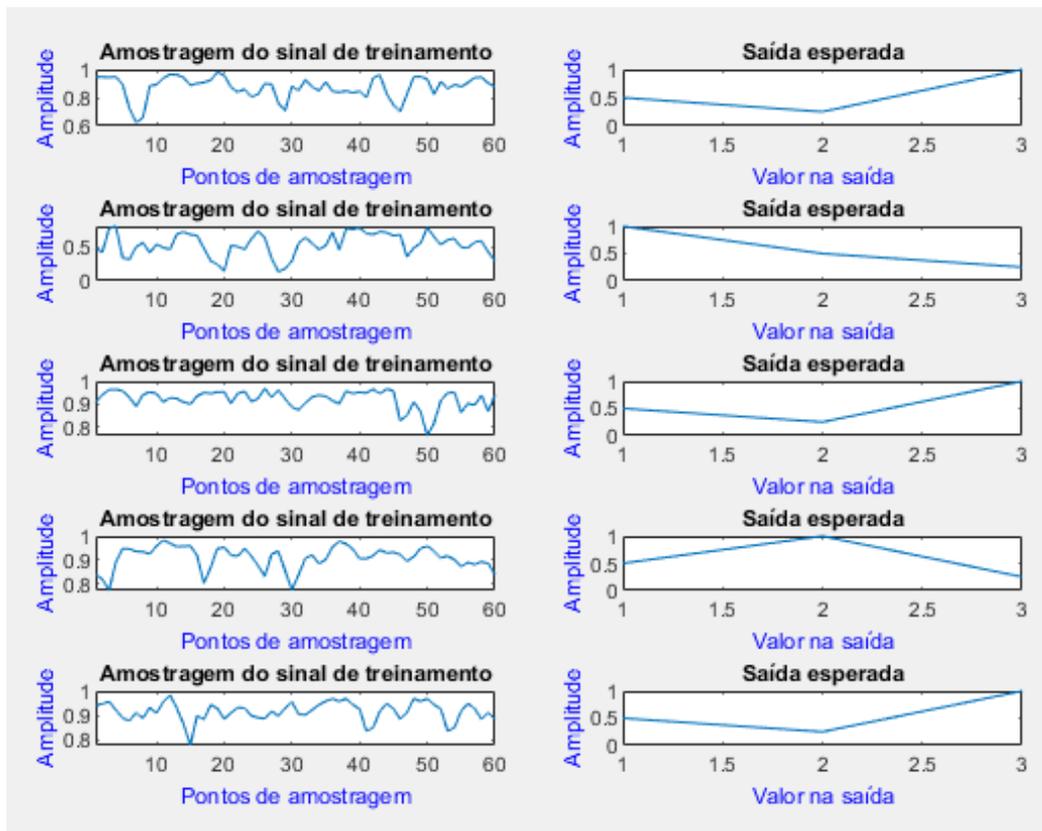
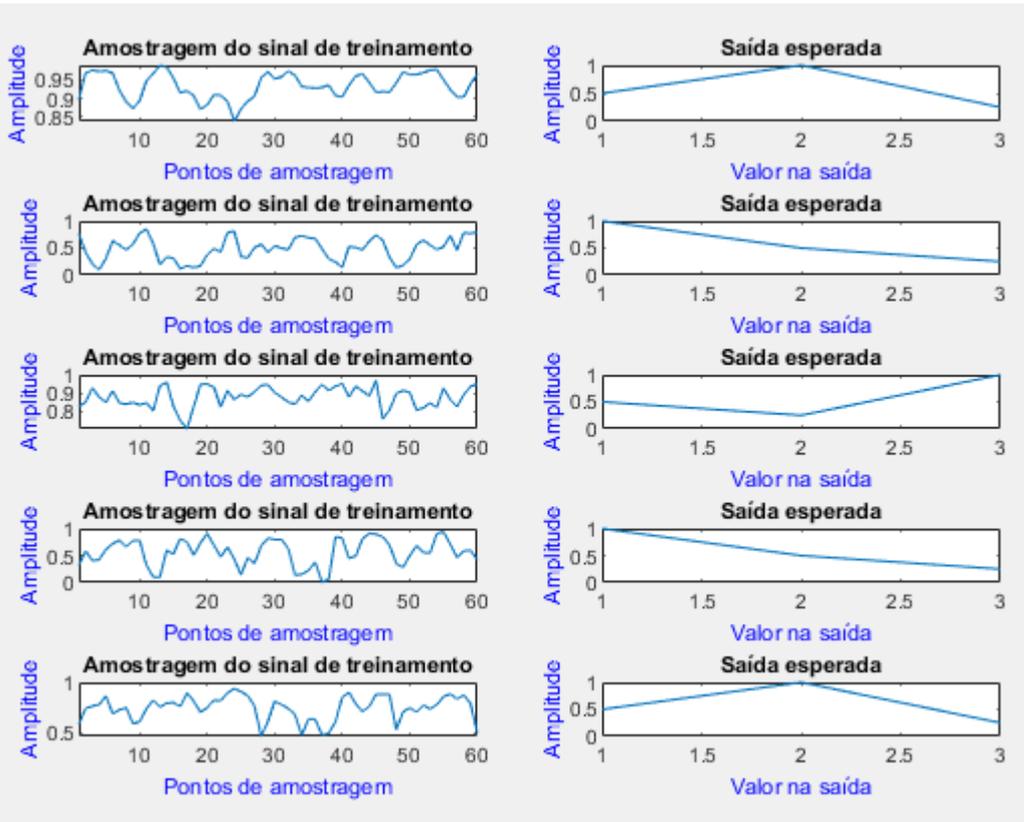
AMOSTRAGENS DE TREINAMENTO RNA-1

50 de 288 amostragens, realizadas em RNA-1



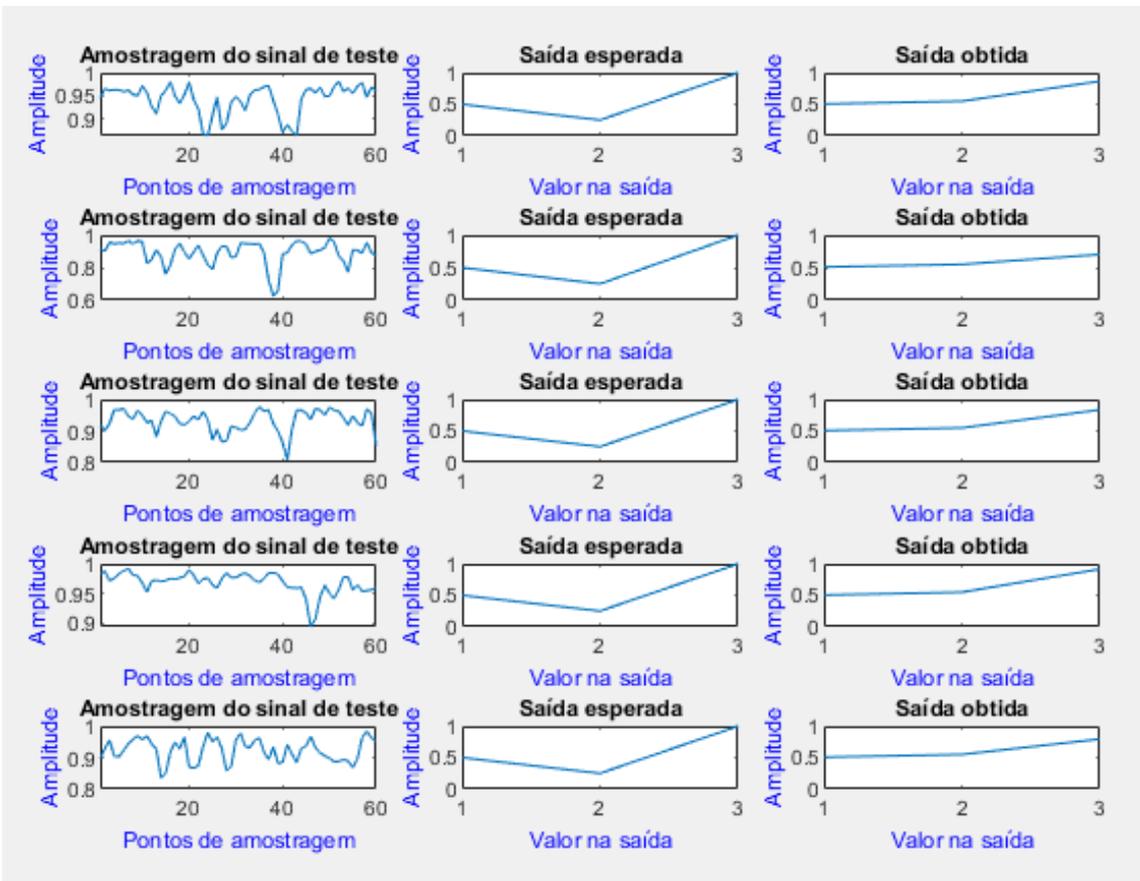
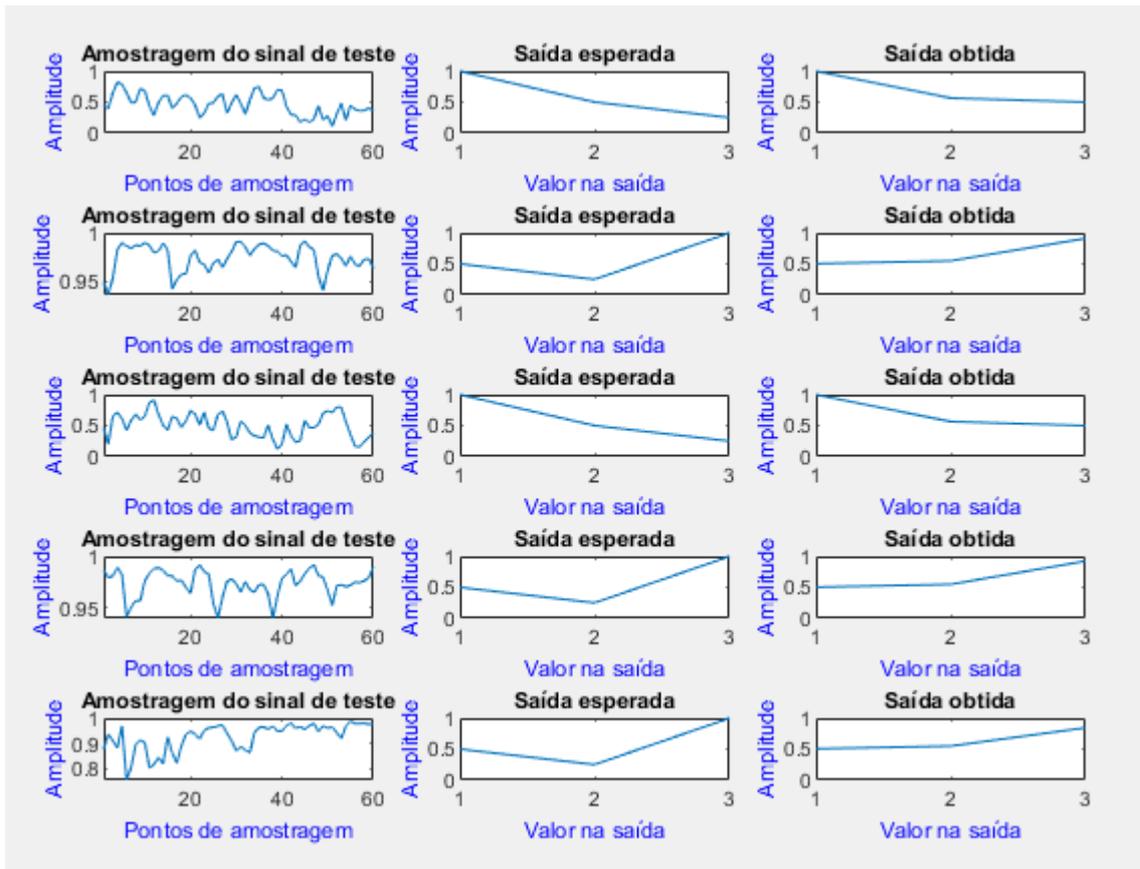


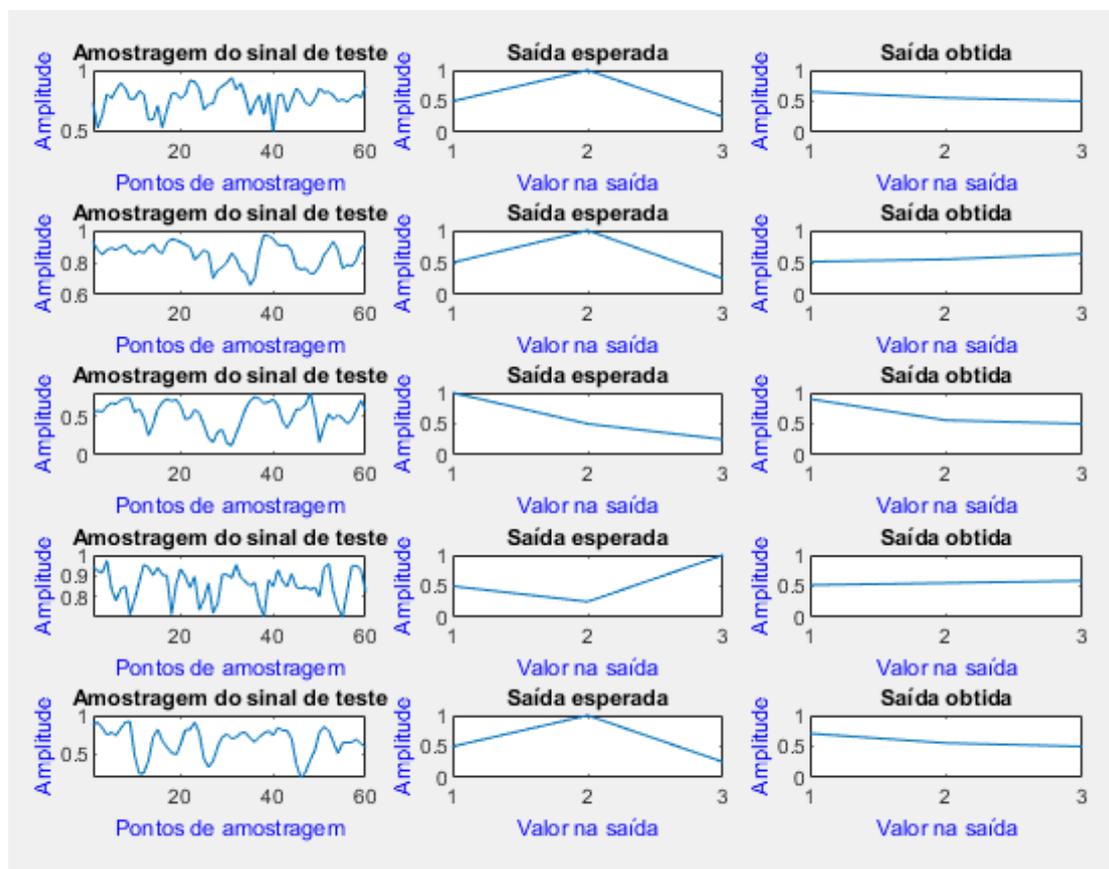
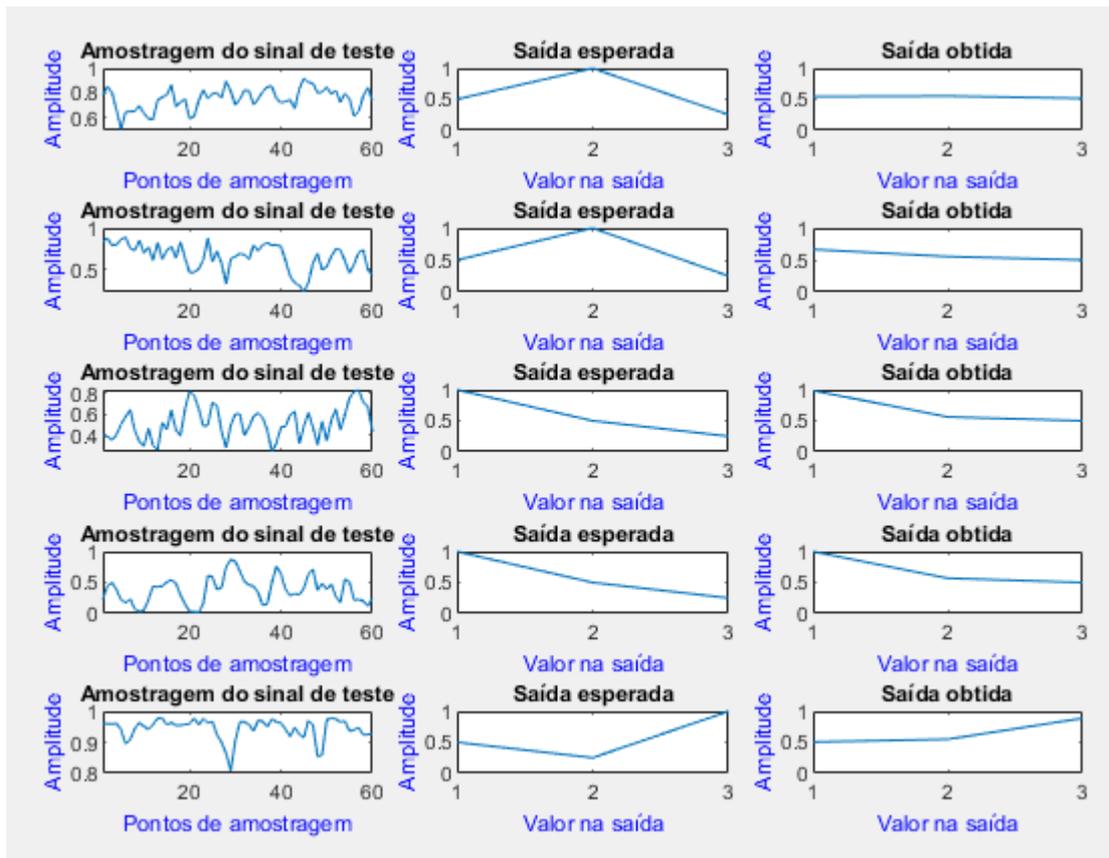


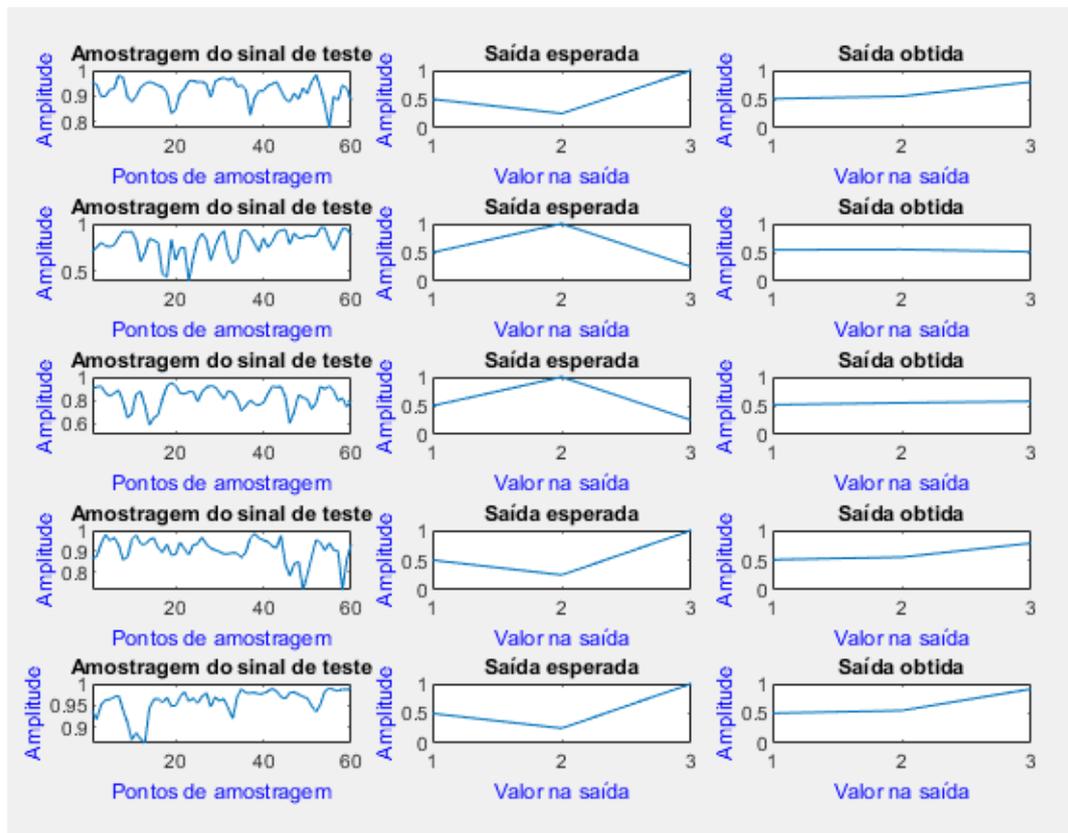
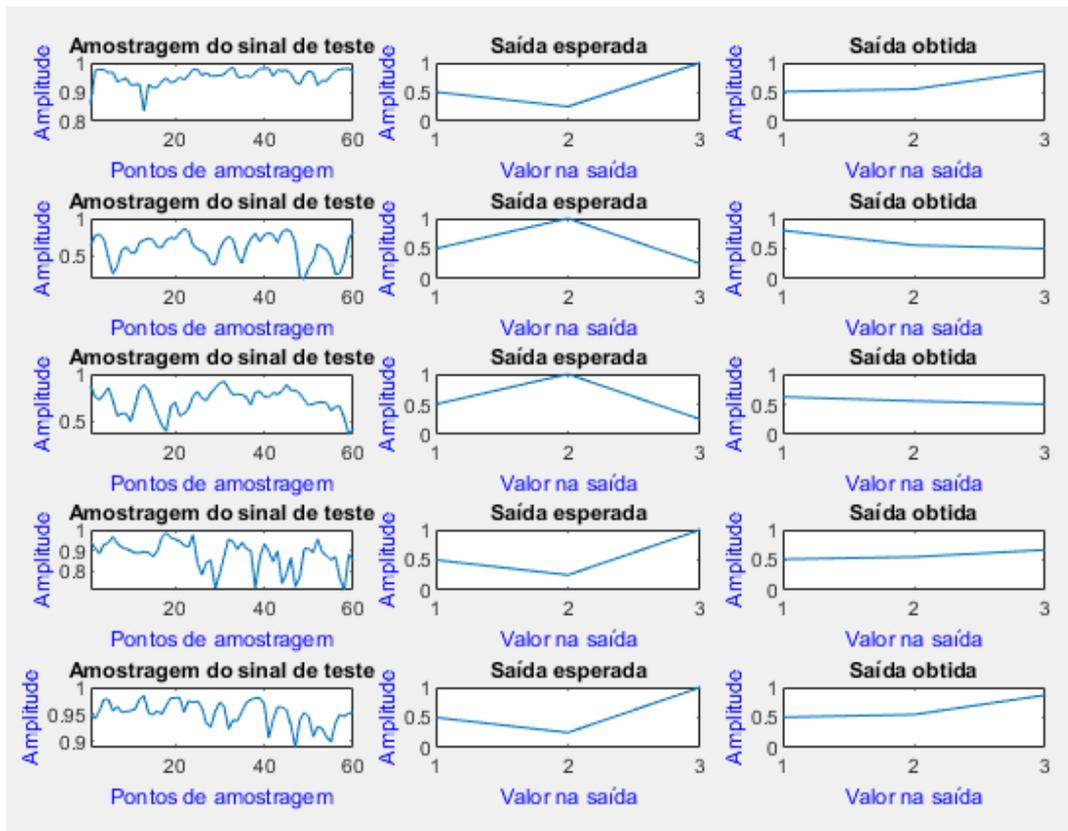


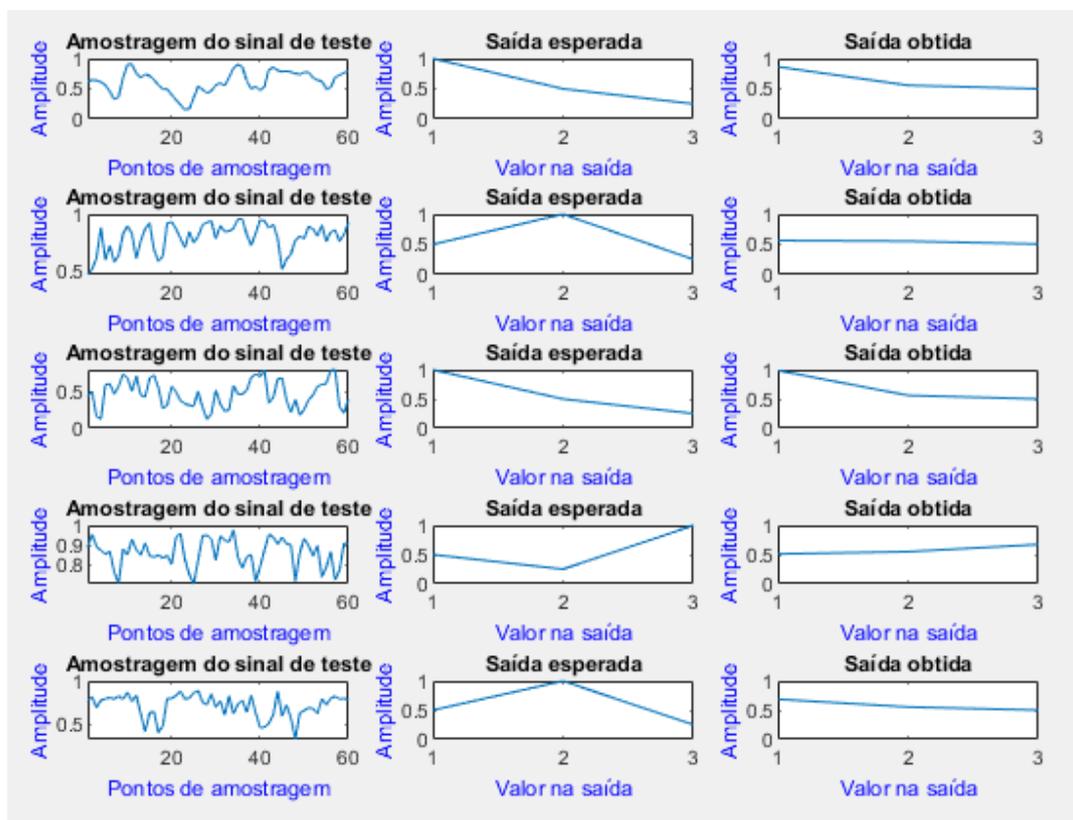
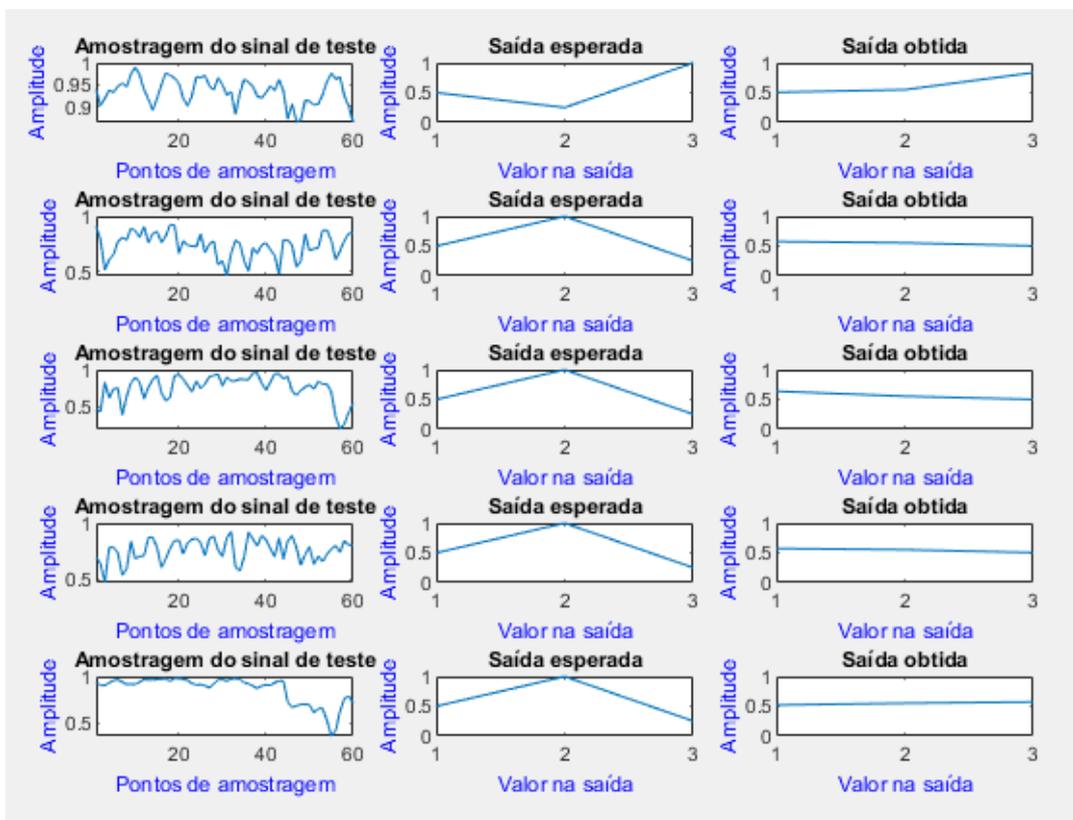
AMOSTRAGENS DE VALIDAÇÃO RNA-1

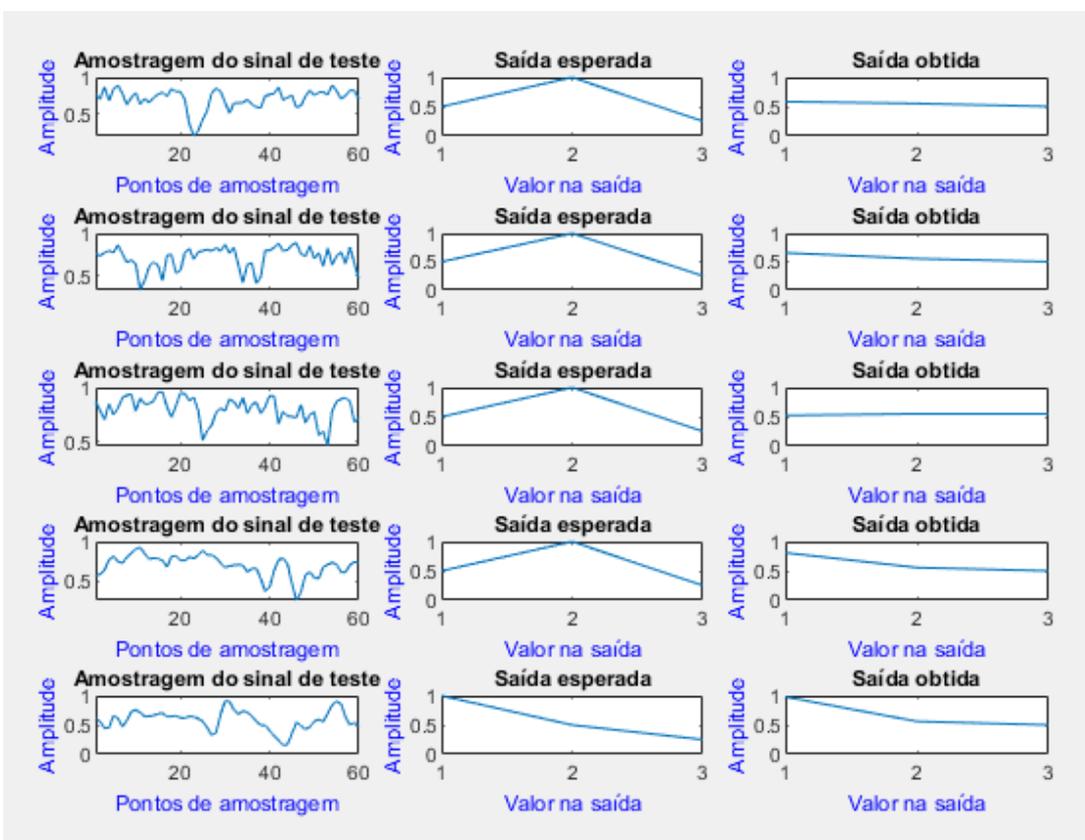
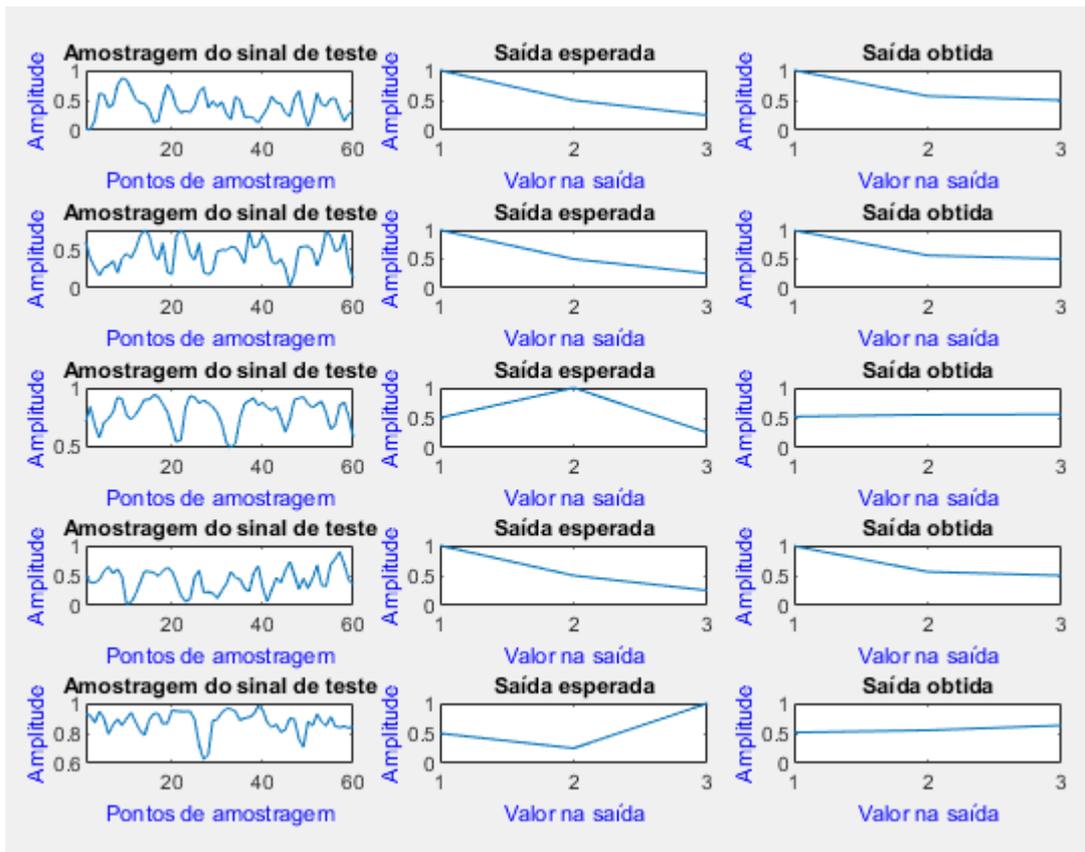
60 de 72 amostragens, realizadas em RNA-1

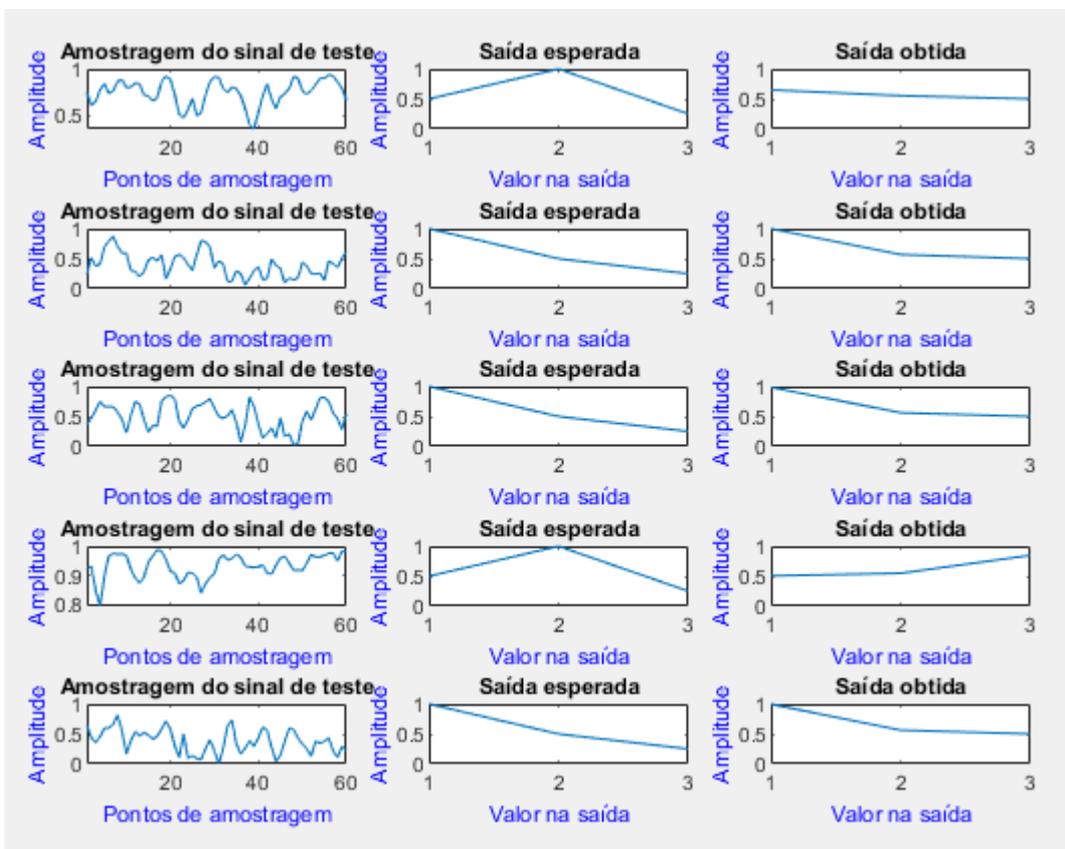
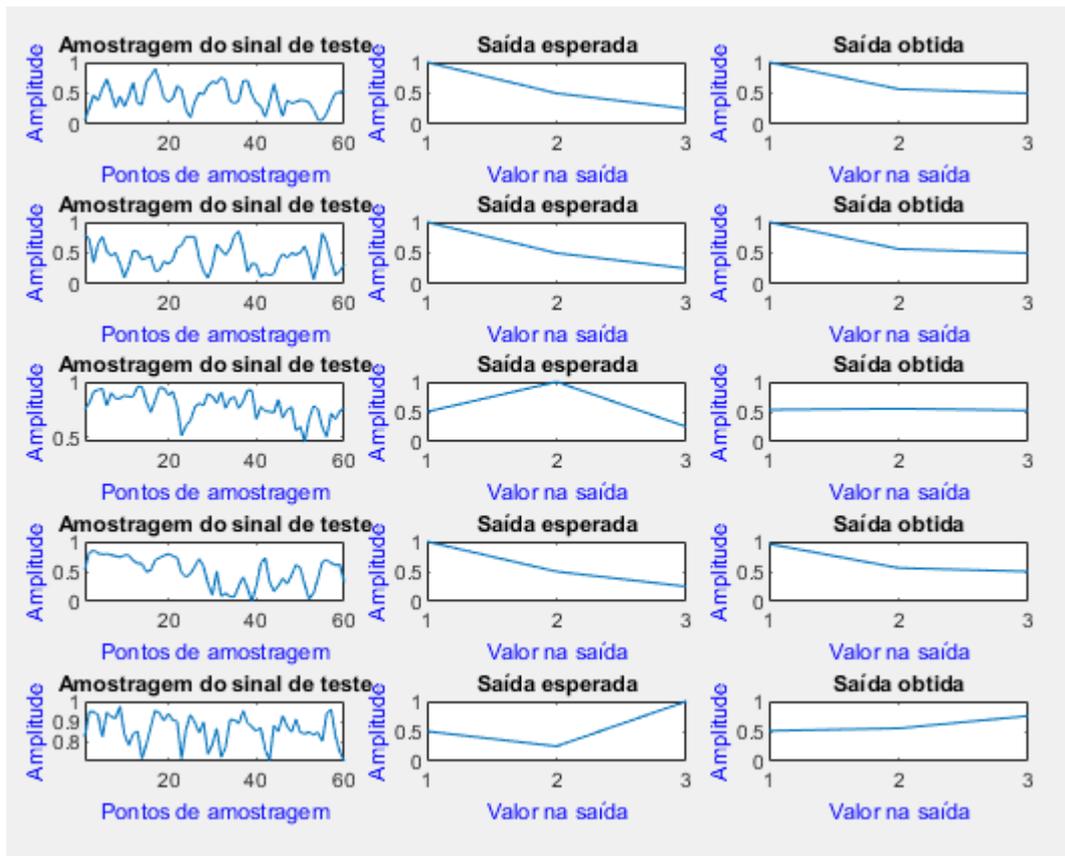






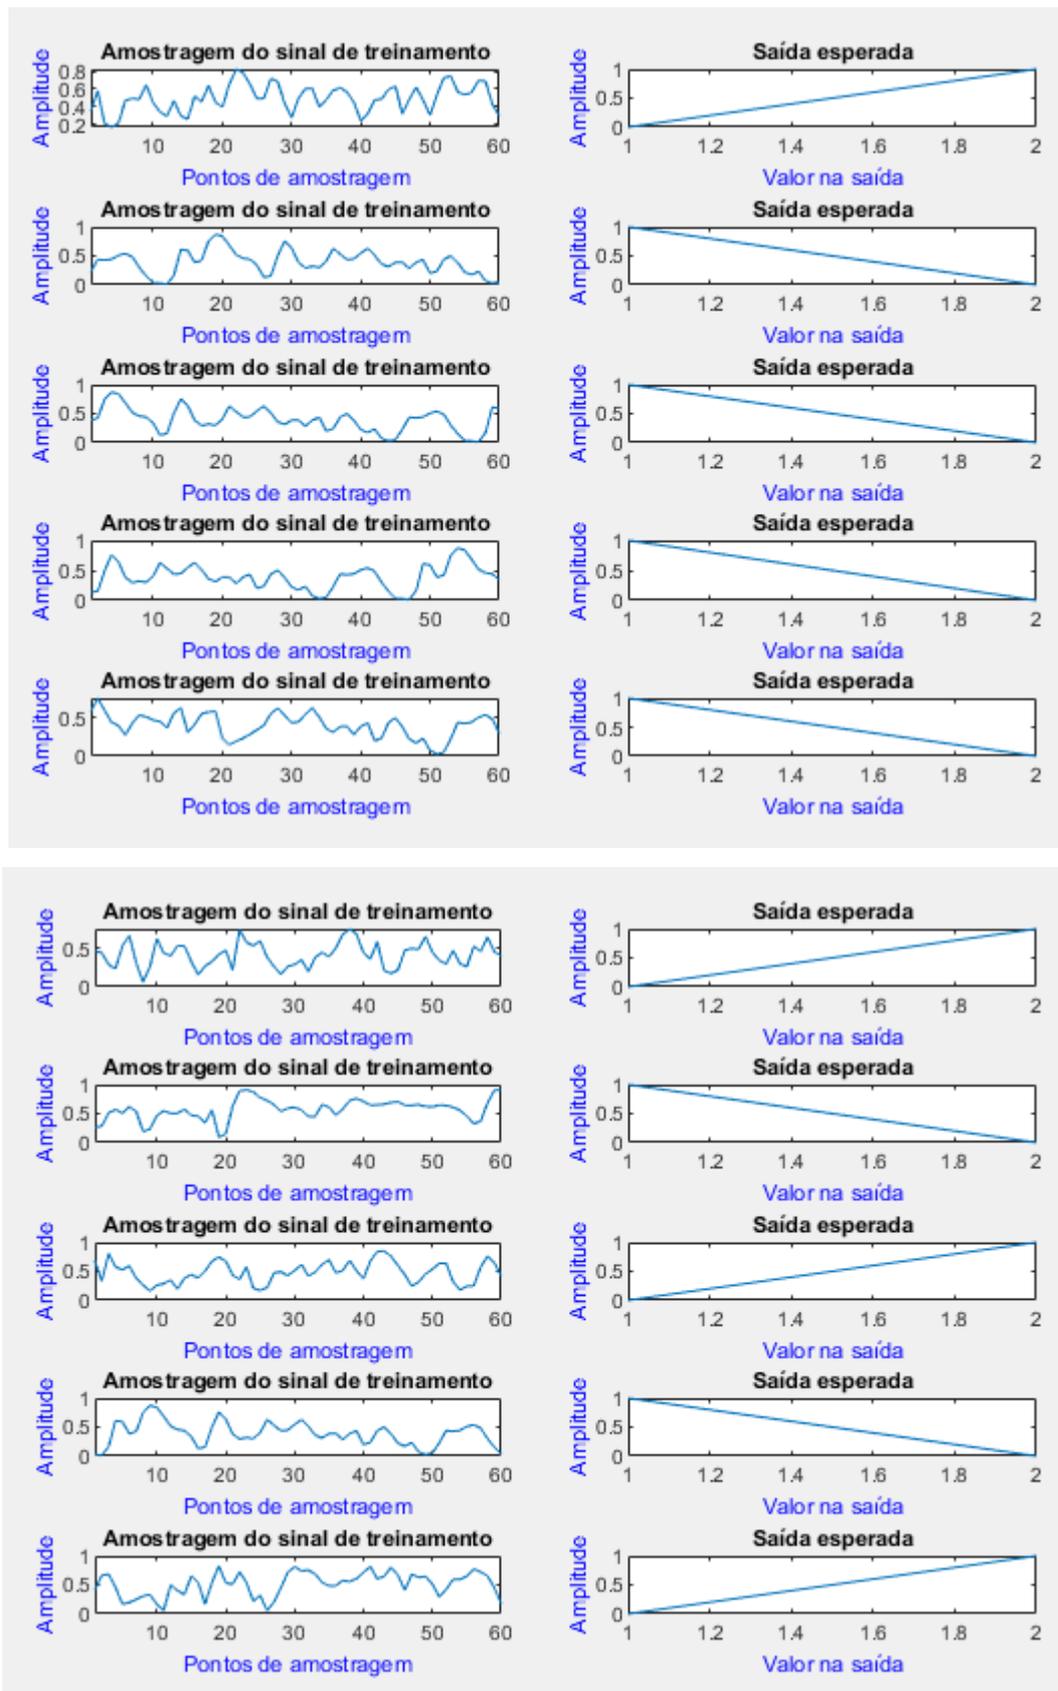


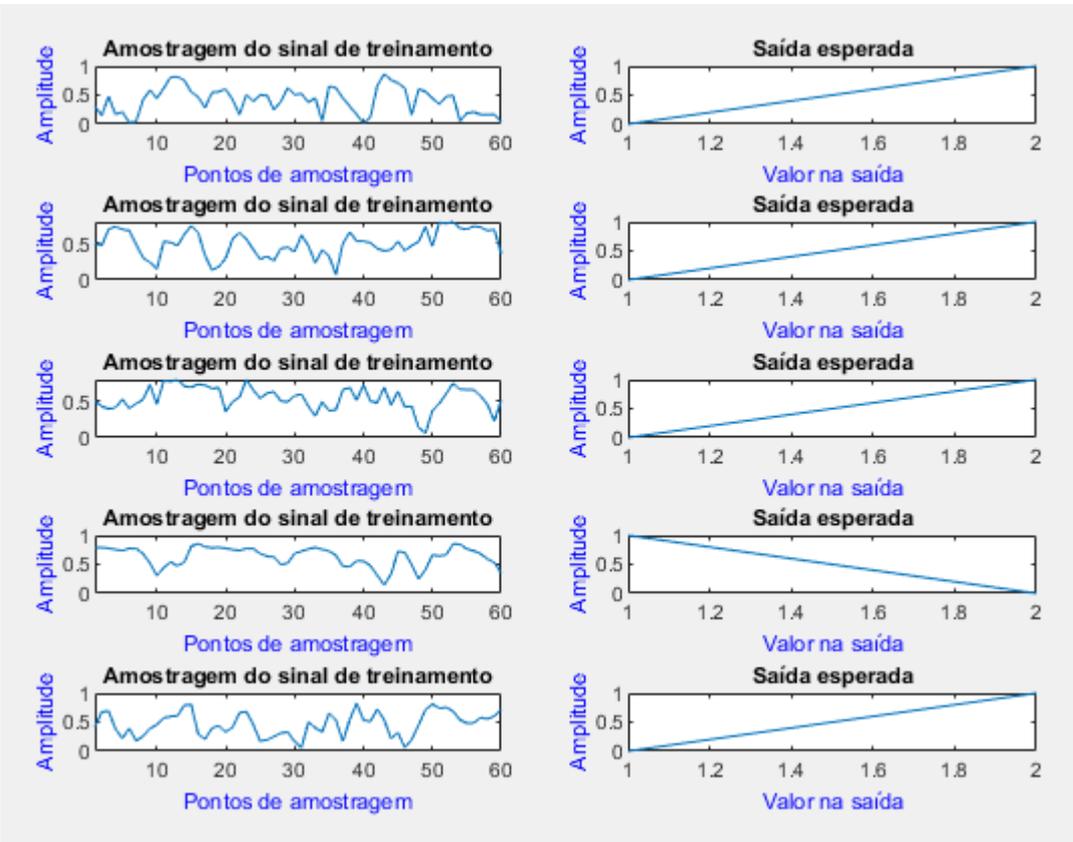
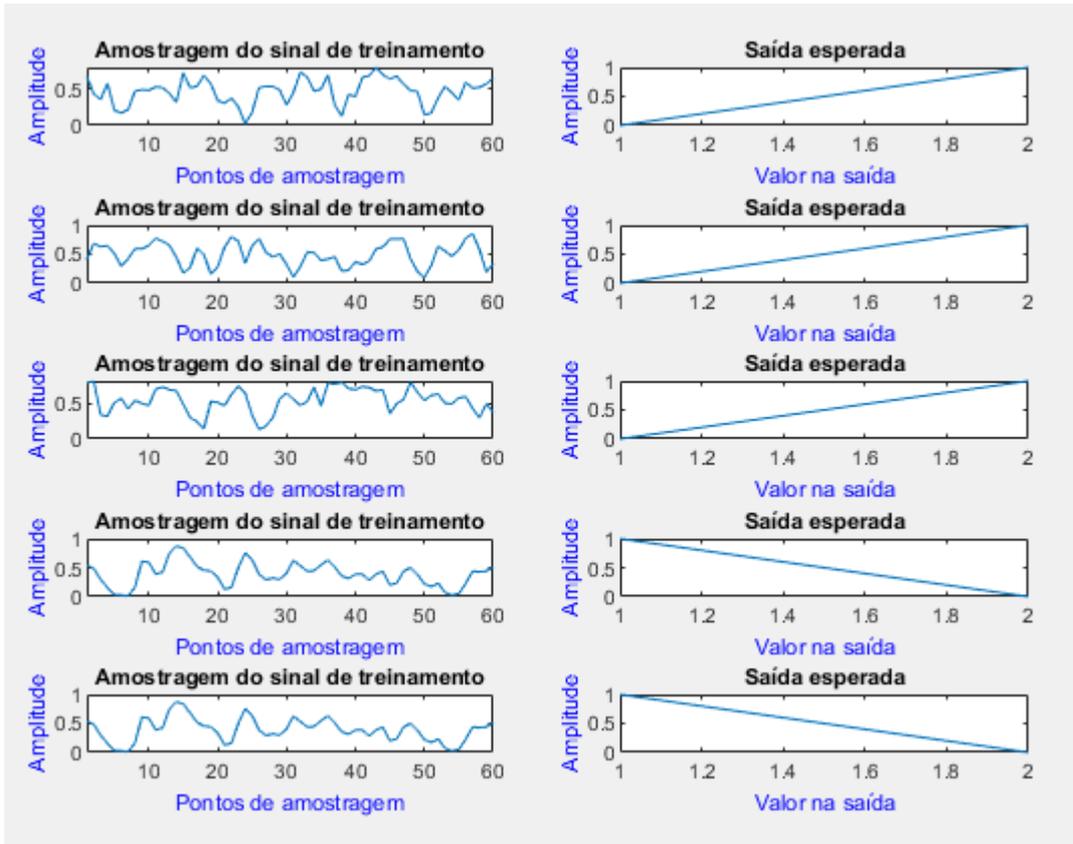




AMOSTRAGENS DE TREINAMENTO RNA-2

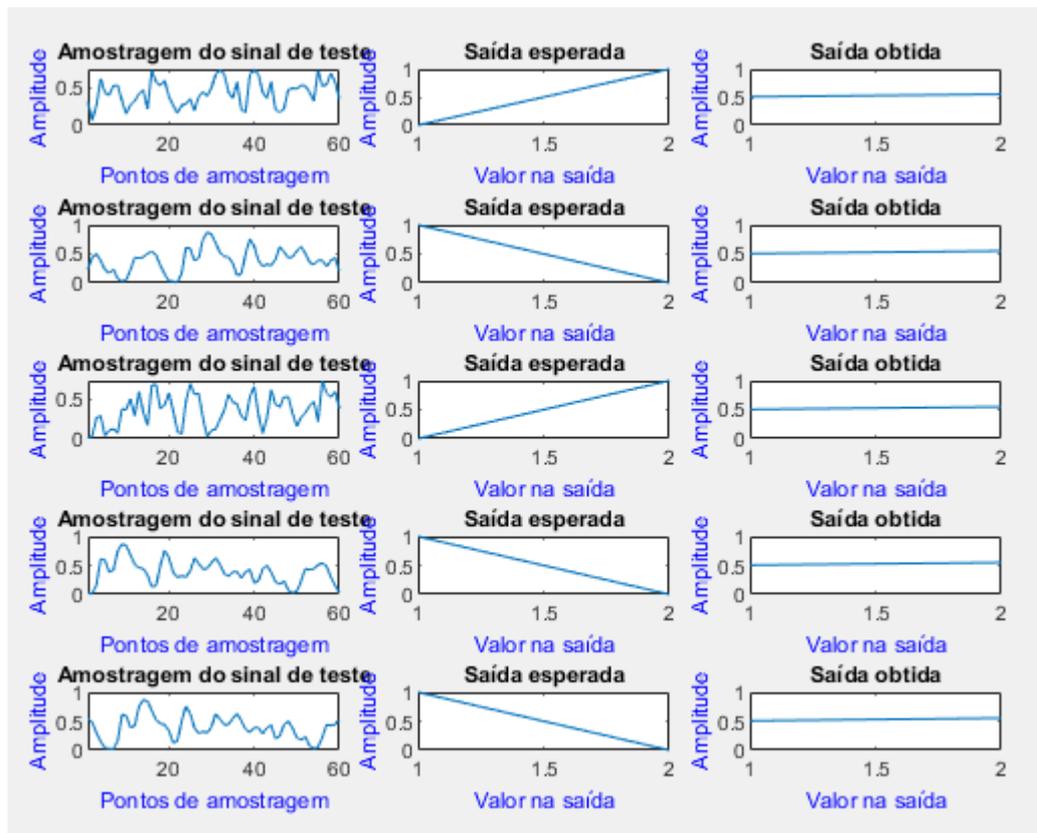
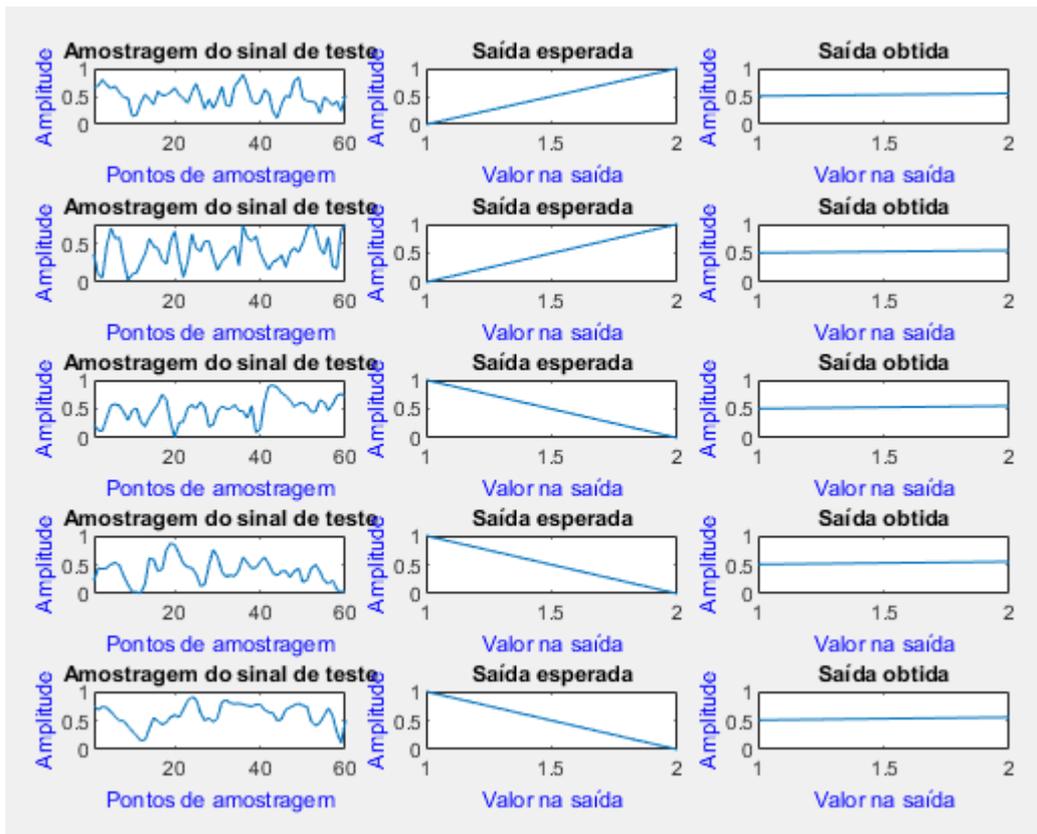
40 de 128 amostragens, realizadas em RNA-2

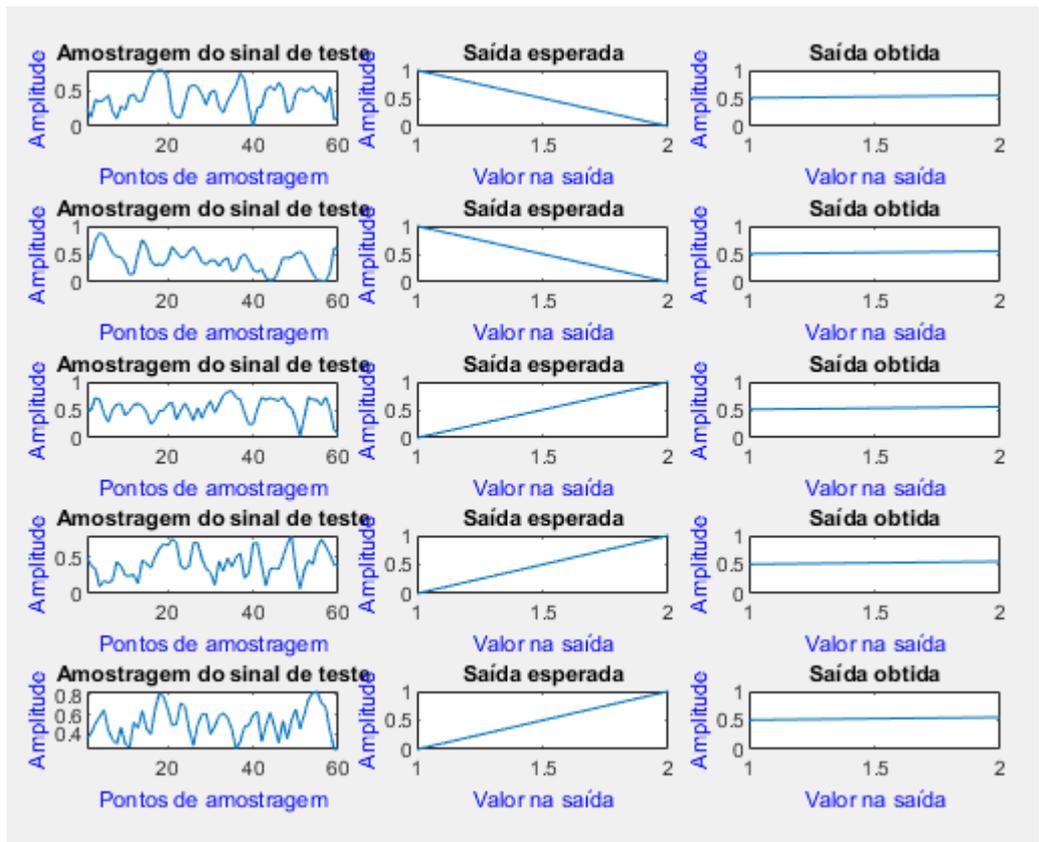
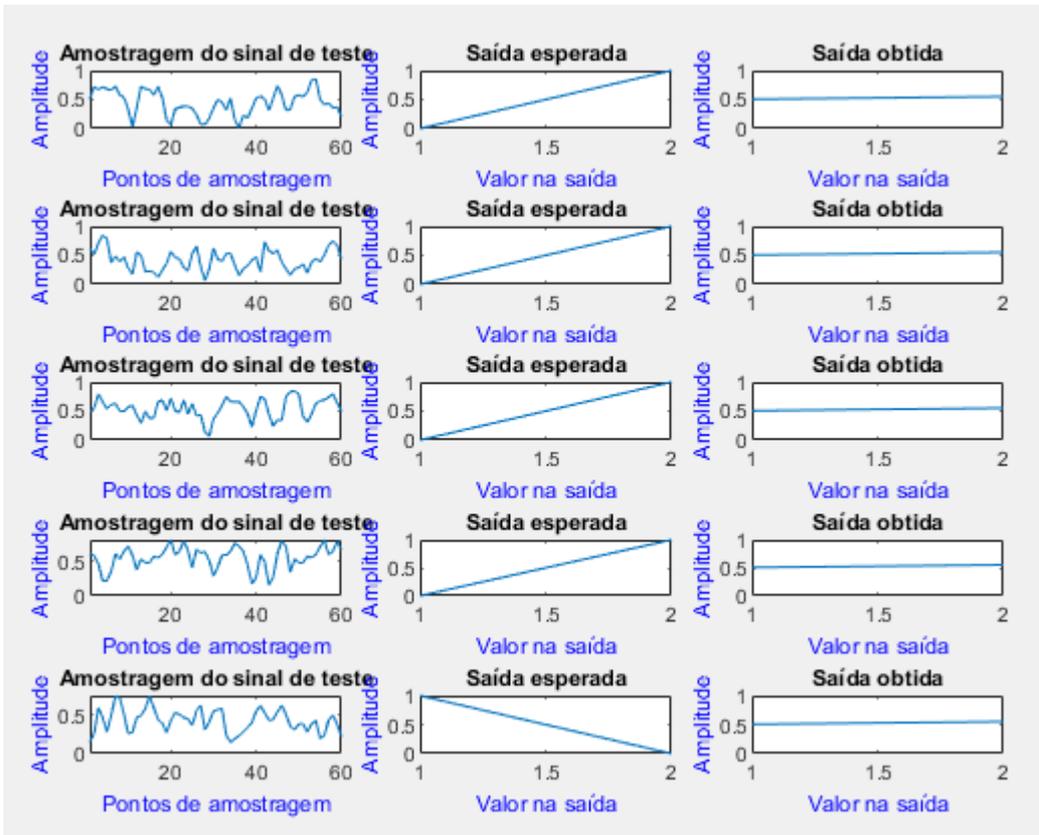




AMOSTRAGENS DE VALIDAÇÃO RNA-2

32 de 32 amostragens, realizadas em RNA-2





Apêndice B

Janelas gráficas do teste

APÊNDICE B

Janelas gráficas do teste

Este apêndice apresenta as janelas gráficas dos testes realizados em 50 indivíduos, selecionados aleatoriamente da base de dados de referência (OpenNeuro), cujos perfis são apresentados em detalhe no Anexo A.

Neste apêndice, cada página com janela gráfica do teste é composta por:

1. Lista com 10 indivíduos, cada um identificado por seu número na base de dados OpenNeuro (Anexo A), apresentados na mesma ordem em que foram selecionados para o teste;
2. Figura com resultados do teste referente aos 10 indivíduos listados, na mesma ordem.

Na primeira janela gráfica, verifica-se que:

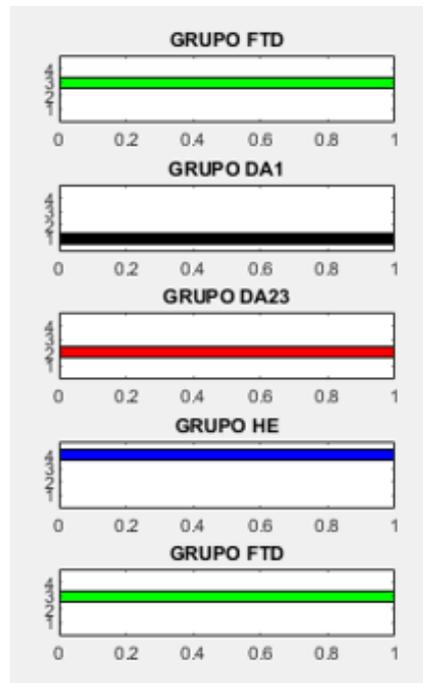
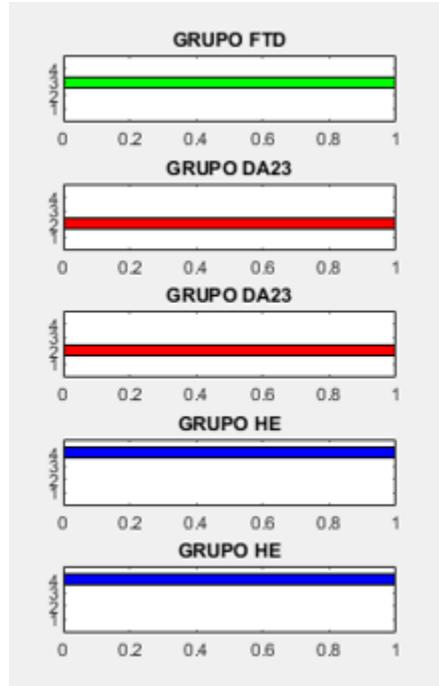
1. O 1º indivíduo listado é identificado pelo número 27 (perfil real na base OpenNeuro igual a AD) e testado como FTD → Erro!
2. O 2º indivíduo listado é identificado pelo número 76 (perfil real na base OpenNeuro igual a FTD) e testado como DA → Erro!
3. O 3º indivíduo listado é identificado pelo número 79 (perfil real na base OpenNeuro igual a FTD) e testado como DA → Erro!
4. O 4º indivíduo listado é identificado pelo número 42 (perfil real na base OpenNeuro igual a HE) e testado como HE → Acerto!
5. O 5º indivíduo listado é identificado pelo número 40 (perfil real na base OpenNeuro igual a HE) e testado como HE → Acerto!
6. O 6º indivíduo listado é identificado pelo número 50 (perfil real na base OpenNeuro igual a HE) e testado como FTD → Erro!
7. O 7º indivíduo listado é identificado pelo número 75 (perfil real na base OpenNeuro igual a FTD) e testado como DA → Erro!
8. O 8º indivíduo listado é identificado pelo número 25 (perfil real na base OpenNeuro igual a AD) e testado como DA → Acerto!
9. O 9º indivíduo listado é identificado pelo número 46 (perfil real na base OpenNeuro igual a HE) e testado como HE → Acerto!
10. O 10º indivíduo listado é identificado pelo número 74 (perfil real na base OpenNeuro igual a FTD) e testado como FTD → Acerto!

Janela gráfica do teste

EEG_DATABASE ✕

1x50 double

1	2	3	4	5	6	7	8	9	10
27	76	79	42	40	50	75	25	46	74

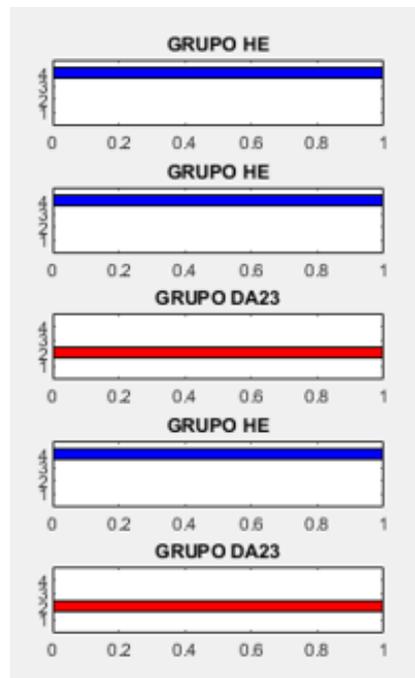
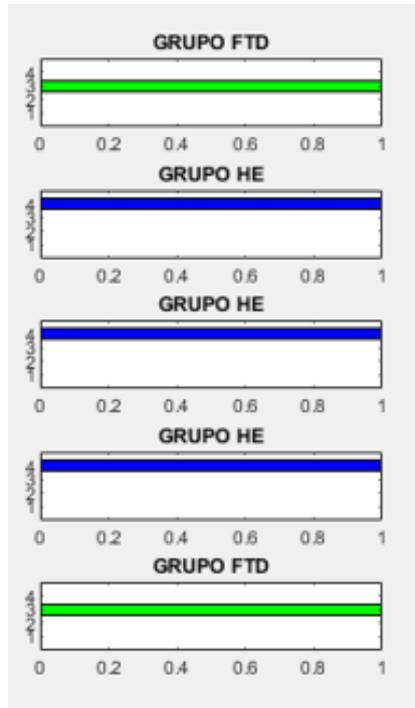


Janela gráfica do teste

EEG_DATABASE

1x50 double

11	12	13	14	15	16	17	18	19	20
85	48	54	43	82	44	45	15	59	34

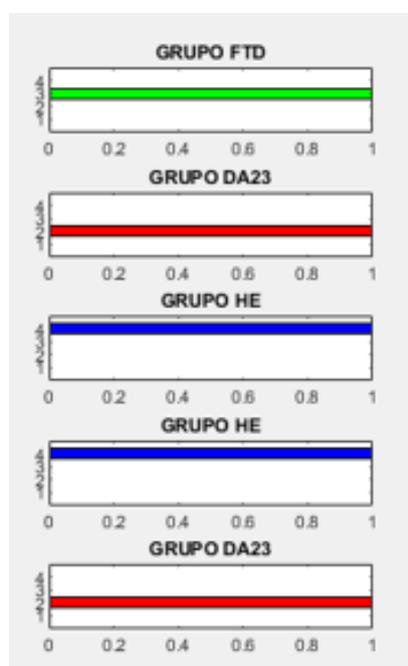
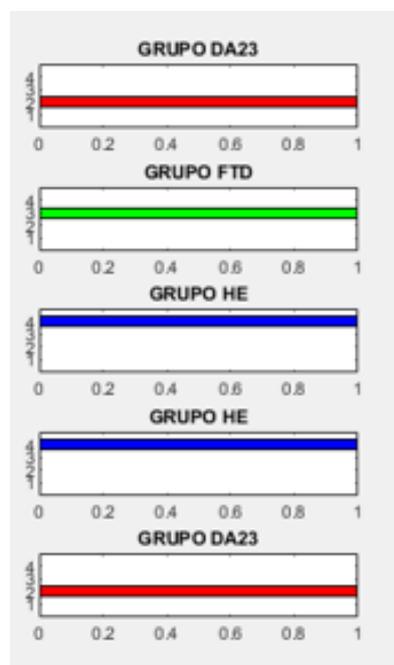


Janela gráfica do teste

EEG_DATABASE

1x50 double

21	22	23	24	25	26	27	28	29	30
1	77	65	41	32	66	20	55	58	13

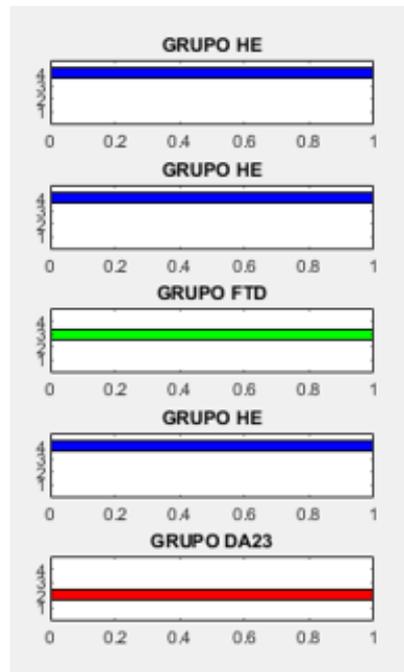
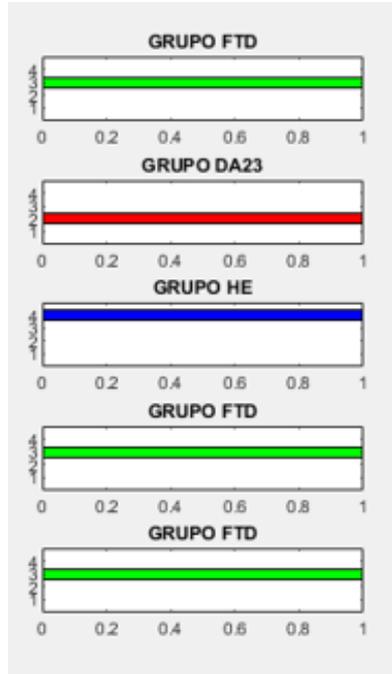


Janela gráfica do teste

EEG_DATABASE ✕

1x50 double

31	32	33	34	35	36	37	38	39	40
53	6	78	8	31	52	49	88	39	33

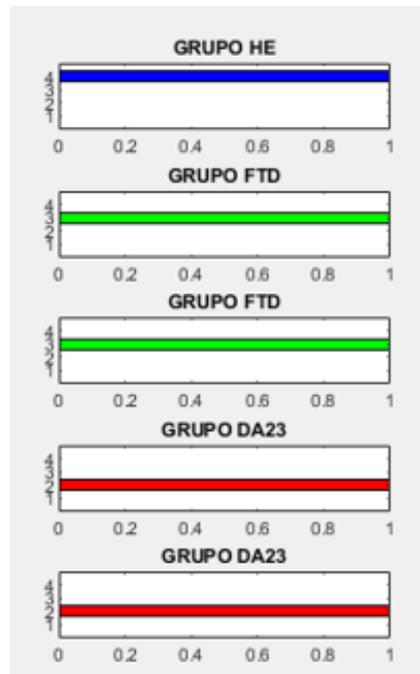
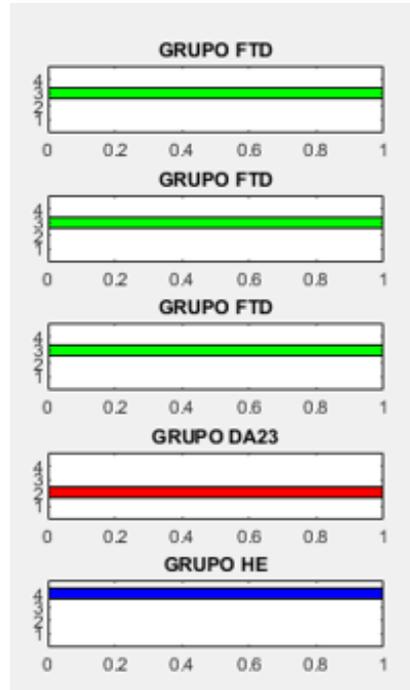


Janela gráfica do teste

EEG_DATABASE

1x50 double

41	42	43	44	45	46	47	48	49	50
83	69	68	9	37	38	81	73	17	35



Anexo A

Referência da Base de Dados

OpenNeuro

ANEXO 1

Participantes da base de dados de referência

participar	Gender	Age	Group	MMSE	Diagnóstic	AVERAGE MMSE
sub-001	F	57	A	16	AD	
sub-002	F	78	A	22	AD	
sub-003	M	70	A	14	AD	
sub-004	F	67	A	20	AD	
sub-005	M	70	A	22	AD	
sub-006	F	61	A	14	AD	
sub-007	F	79	A	20	AD	
sub-008	M	62	A	16	AD	
sub-009	F	77	A	23	AD	
sub-010	M	69	A	20	AD	
sub-011	M	71	A	22	AD	
sub-012	M	63	A	18	AD	
sub-013	F	64	A	20	AD	
sub-014	M	77	A	14	AD	
sub-015	M	61	A	18	AD	
sub-016	F	68	A	14	AD	
sub-017	F	61	A	6	AD	
sub-018	F	73	A	23	AD	
sub-019	F	62	A	14	AD	
sub-020	M	71	A	4	AD	
sub-021	M	79	A	22	AD	
sub-022	F	68	A	20	AD	
sub-023	M	60	A	16	AD	
sub-024	F	69	A	20	AD	
sub-025	F	79	A	20	AD	
sub-026	F	61	A	18	AD	
sub-027	F	67	A	16	AD	
sub-028	M	49	A	20	AD	
sub-029	F	53	A	16	AD	
sub-030	F	56	A	20	AD	
sub-031	F	67	A	22	AD	
sub-032	F	59	A	20	AD	
sub-033	F	72	A	20	AD	
sub-034	F	75	A	18	AD	
sub-035	F	57	A	22	AD	
sub-036	F	58	A	9	AD	
						17,75

participant	Gender	Age	Group	MMSE	Diagnóstico	AVERAGE MMSE
sub-037	M	57	C	30	HE	
sub-038	M	62	C	30	HE	
sub-039	M	70	C	30	HE	
sub-040	M	61	C	30	HE	
sub-041	F	77	C	30	HE	
sub-042	M	74	C	30	HE	
sub-043	M	72	C	30	HE	
sub-044	F	64	C	30	HE	
sub-045	F	70	C	30	HE	
sub-046	M	63	C	30	HE	
sub-047	F	70	C	30	HE	
sub-048	M	65	C	30	HE	
sub-049	F	62	C	30	HE	
sub-050	M	68	C	30	HE	
sub-051	F	75	C	30	HE	30
sub-052	F	73	C	30	HE	
sub-053	M	70	C	30	HE	
sub-054	M	78	C	30	HE	
sub-055	M	67	C	30	HE	
sub-056	F	64	C	30	HE	
sub-057	M	64	C	30	HE	
sub-058	M	62	C	30	HE	
sub-059	M	77	C	30	HE	
sub-060	F	71	C	30	HE	
sub-061	F	63	C	30	HE	
sub-062	M	67	C	30	HE	
sub-063	M	66	C	30	HE	
sub-064	M	66	C	30	HE	
sub-065	F	71	C	30	HE	

participant	Gender	Age	Group	MMSE	Diagnóstico	AVERAGE MMSE
sub-066	M	73	F	20	FTD	22,17
sub-067	M	66	F	24	FTD	
sub-068	M	78	F	25	FTD	
sub-069	M	70	F	22	FTD	
sub-070	F	67	F	22	FTD	
sub-071	M	62	F	20	FTD	
sub-072	M	65	F	18	FTD	
sub-073	F	57	F	22	FTD	
sub-074	F	53	F	20	FTD	
sub-075	F	71	F	22	FTD	
sub-076	M	44	F	24	FTD	
sub-077	M	61	F	22	FTD	
sub-078	M	62	F	22	FTD	
sub-079	F	60	F	18	FTD	
sub-080	F	71	F	20	FTD	
sub-081	F	61	F	18	FTD	
sub-082	M	63	F	27	FTD	
sub-083	F	68	F	20	FTD	
sub-084	F	71	F	24	FTD	
sub-085	M	64	F	26	FTD	
sub-086	M	49	F	26	FTD	
sub-087	M	73	F	24	FTD	
sub-088	M	55	F	24	FTD	

Posição de leitura dos eletrodos

senal	posição	SOBRE
Fp1	1	As informações relativas ao posicionamento dos eletrodos dos sinais e várias outras estão disponíveis no arquivo de info, recebido na operação de leitura do sinal EEG. (Ex. Signal_INFO)
Fp2	2	
F3	3	
F4	4	
C3	5	
C4	6	
P3	7	
P4	8	
O1	9	
O2	10	
F7	11	
F8	12	
T3	13	
T4	14	
T5	15	
T6	16	
Fz	17	
Cz	18	
Pz	19	